

UNIVERSIDADE FEDERAL DE SANTA CATARINA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**ABORDAGEM NÃO-LINEAR PARA MODELAGEM
E CONTROLE PREDITIVO: ESTUDO DE CASO**

DISSERTAÇÃO SUBMETIDA À UNIVERSIDADE FEDERAL DE
SANTA CATARINA PARA A OBTENÇÃO DO TÍTULO DE
MESTRE EM ENGENHARIA ELÉTRICA

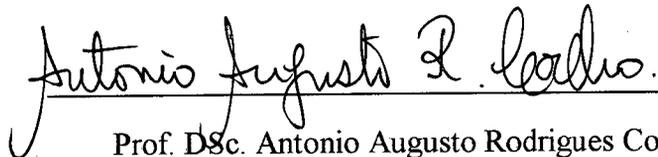
Pierre Alibert Marchi

Florianópolis – SC – Brasil
Fevereiro de 1999

ABORDAGEM NÃO-LINEAR PARA MODELAGEM E CONTROLE PREDITIVO: ESTUDO DE CASO

Pierre Alibert Marchi

Esta dissertação foi julgada adequada para obtenção do título de **Mestre em Engenharia Elétrica**, área de concentração **Controle, Automação e Informática Industrial** e aprovada em sua forma final pelo curso de pós-graduação



Prof. DSc. Antonio Augusto Rodrigues Coelho
Orientador

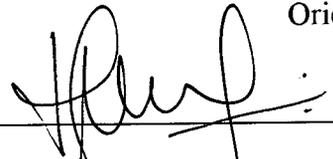


Prof. Dr. Ildemar Cassana Decker,
Coordenador do Curso de Pós-Graduação
em Engenharia Elétrica

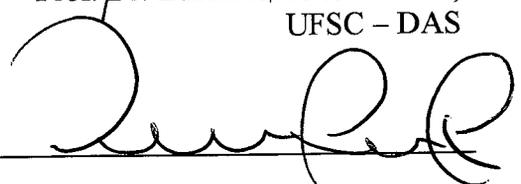
Banca Examinadora



Prof. DSc. Antonio Augusto Rodrigues Coelho
Orientador



Prof. Dr. Edson Roberto de Pieri,
UFSC – DAS



Prof. Werner Kraus Jr., Ph.D.
UFSC – DAS

**“A ciência fez de nós deuses antes de
merecermos ser homens”**

Jean Rostand

Aos Meus Pais,
Milton e Dóris.

AGRADECIMENTOS

A Deus, pela minha existência e por todas as coisas boas e “ruins” que tem acontecido na minha vida e que me fizeram crescer como pessoa.

A minha família, pelo apoio, compreensão e carinho que têm me dado durante a minha vida.

Aos amigos do *LCMI* e de Floripa que muito me ajudaram neste período com o seu companheirismo e amizade, em especial a Karina, Karen, Jorge, Marcos M., Marcos V., Carlos Venturo, Carlos Rocha, Sandro, Cesar, Miguel, Sobral, Howard, Vitor e Lau.

Ao professor Antonio Augusto Rodrigues Coelho, pela orientação e dedicação demonstrada em todas as etapas deste trabalho.

Aos integrantes do Laboratório de Controle de Processos (*LCP*), em especial aos colegas Henrique Simas e Leandro dos Santos Coelho, pelas valiosas contribuições para a confecção deste trabalho.

A todos os professores e colegas do *LCMI* que contribuíram neste período de aprendizado.

Ao CNPq pelo apoio financeiro.

RESUMO

Técnicas de controle preditivo adaptativo são objeto de extensos trabalhos na área acadêmica e nota-se uma forte tendência da aplicação de tais técnicas na indústria. Isto se deve à robustez e à habilidade de tais controladores em lidarem com vários tipos de sistemas complexos. Uma possível desvantagem para tais controladores reside no fato de utilizarem modelos lineares para representarem o sistema, que, em geral, é não-linear. Este trabalho se propõe a estudar e comparar vários tipos de modelos não-lineares e de controladores baseados nestes modelos, bem como comparar o desempenho de dois diferentes estimadores de parâmetros, estimador preditivo e o mínimos quadrados recursivo.

Para uma melhor análise do desempenho dos controladores, assim como da capacidade de representação dos modelos, foram realizadas experiências de identificação e seguimento de trajetória no processo não-linear, *Fan and Plate*.

ABSTRACT

Techniques of adaptive predictive control are the main subject of many works in the academic area and it can be observed, in the last decade, an increasing trend in industry towards the application of such techniques. This is due to robustness aspects and the ability to deal with several types of complex systems. A possible disadvantage for such controllers resides in the fact that they use linear models to represent the system, which is generally nonlinear. This work studies and compares several types of nonlinear models and controllers based on these models, as well as compares the performance of two different parameters estimators, the predictive estimator and the recursive least squares method.

For a better assessment of the controller's performance, as well as the capacity of representation of the models, identification and trajectory tracking experiments were carried out on a nonlinear process, known in the literature as Fan and Plate.

SUMÁRIO

RESUMO	vi
<i>ABSTRACT</i>	vii
1. INTRODUÇÃO	1
1.1 Controle adaptativo preditivo	2
1.2 Identificação de sistemas	3
1.3 Motivações e objetivos	4
1.4 Estrutura da dissertação	5
2. ALGORITMOS DE ESTIMAÇÃO	7
2.1 Introdução	7
2.2 Algoritmo dos mínimos quadrados recursivo	8
2.3 Estimador preditivo	10
2.4 Conclusão	12
3. MODELAGEM DE SISTEMAS	13
3.1 Introdução	13
3.2 Modelo linear	15
3.3 Modelo de Hammerstein	17
3.4 Modelo bilinear	19
3.5 Modelo de Volterra	20

3.6 Múltiplos modelos	21
3.7 Conclusão	23
4. CONTROLE PREDITIVO	24
4.1 Introdução	24
4.2 Controlador <i>GPC</i>	25
4.3 Controle preditivo baseado no modelo de Hammerstein	28
4.4 Controle preditivo baseado no modelo de Volterra	29
4.5 Controlador preditivo não-linear	31
4.6 Controle preditivo utilizando múltiplos modelos	32
4.7 Conclusão	33
5. RESULTADOS EXPERIMENTAIS	35
5.1 Introdução	35
5.2 <i>Fan and Plate</i>	36
5.3 Experimentos	37
5.3.1 Modelagem	38
5.3.2 Mudança de <i>Setpoint</i>	41
5.4 Conclusão	45
6. COMENTÁRIOS E CONCLUSÃO	46
REFERÊNCIAS BIBLIOGRÁFICAS	48

1. Introdução

Os requisitos operacionais necessários para um adequado controle de sistemas são rapidez, precisão e estabilidade. Alcançar tais metas em sistemas complexos, na presença de incertezas do processo a ser controlado, é o desafio para o pesquisador em controle. A percepção de que técnicas de controle convencionais não possuem todos os atributos necessários para a obtenção de tal controle fez com que, nos últimos anos, surgissem várias definições de controle inteligente. Pode-se considerar que controle inteligente seja meramente a habilidade do sistema de controle em operar, com sucesso, em uma grande variedade de situações, detectando a situação específica vigente e tratando-a adequadamente. Perturbações externas, mudanças nas dinâmicas dos subsistemas, variações paramétricas, são exemplos de diferentes ambientes desconhecidos nos quais um sistema deve operar (Narendra e Balakrishnan, 1997).

O controle adaptativo, ou auto-ajustável, apresenta tal habilidade em certo nível. Esta técnica surgiu na década de 70, e desde então tem sido aplicada, em todas as suas formas, com certo sucesso em processos industriais. Tais algoritmos de controle baseiam-se numa lei de controle por realimentação, dada por uma equação a diferenças, a qual atua sobre um determinado conjunto de variáveis medidas (saída do sistema, referência, sinal de controle, estimação do ruído), gerando o novo sinal de controle. Um estimador recursivo em tempo

real monitora estes valores e calcula o conjunto de parâmetros estimados para o modelo representativo da planta (Sales e Billings, 1990).

Muitas pesquisas foram dedicadas ao controle adaptativo, levando ao surgimento de várias e diferentes técnicas de controle. Dentre as quais, destaca-se o algoritmo de controle preditivo adaptativo (Qin e Badgwell, 1996).

1.1 Controle preditivo adaptativo

Durante a última década, algoritmos de controle preditivo têm mostrado seus benefícios e, pouco a pouco, vêm substituindo os tradicionais controladores manualmente ajustáveis (Roux *et al.*, 1996). Uma pesquisa realizada por Qin e Badgwell, (1996), entre cinco companhias americanas que comercializam controladores preditivos, mostrou que existem mais de 2000 controladores preditivos aplicados em vários ramos da indústria, como a petroquímica, metalúrgica e automotiva, com maior concentração na área de refino. A popularidade do controlador preditivo baseia-se na sua eficiência, robustez e aspectos essenciais para aplicações em tempo real.

A estratégia de controle preditivo baseia-se nos seguintes passos:

- A cada “presente momento t ”, é feita uma previsão da saída do processo sobre um determinado horizonte no tempo (l períodos de amostragem). Esta previsão é feita de maneira explícita no algoritmo de controle e baseia-se no modelo matemático adotado para representar o sistema;
- Dos vários cenários propostos para o controle, deve-se selecionar aquele que traz a saída prevista para o *setpoint*, da “melhor maneira” de acordo com um objetivo de controle especificado;
- O melhor candidato selecionado é então aplicado como uma ação de controle ao processo, porém apenas no presente momento. No próximo período de amostragem, todo o procedimento é então repetido, levando a uma ação de controle atualizada com correções baseadas nas últimas medidas (De Keyser *et al.*, 1988).

Convém ressaltar que, em geral, os controladores preditivos adaptativos baseiam-se em modelos lineares cujos parâmetros são estimados através do algoritmo dos mínimos quadrados recursivo. Na figura 1.1 está ilustrado o esquema de controle preditivo adaptativo.

Existem vários tipos de controladores que se baseiam neste princípio, por exemplo o *MAC (Model Algorithmic Control)*, *DMC (Dynamic Matrix Control)*, *EPSAC (Extended Prediction Self-adaptive Control)*, com destaque especial para o controlador preditivo generalizado ou *GPC (Generalized Predictive Control)*. Apresentado por Clarke em 1987, tornou-se um dos mais populares por uma série de razões: i) utiliza um modelo *CARIMA (Controlled Auto-Regressive Integrated Moving-Average)* e evita problemas de *offset*; ii) considera no objetivo do controle o erro e o esforço de controle futuros ponderado ; iii) apresenta flexibilidade de sintonia para um aplicação particular e; iv) habilidade para incluir restrições e filtros no controle e estimação. Estas características tornam o *GPC* seguro e eficaz para controlar uma variedade de processos experimentais (Zhu *et al.*, 1991).

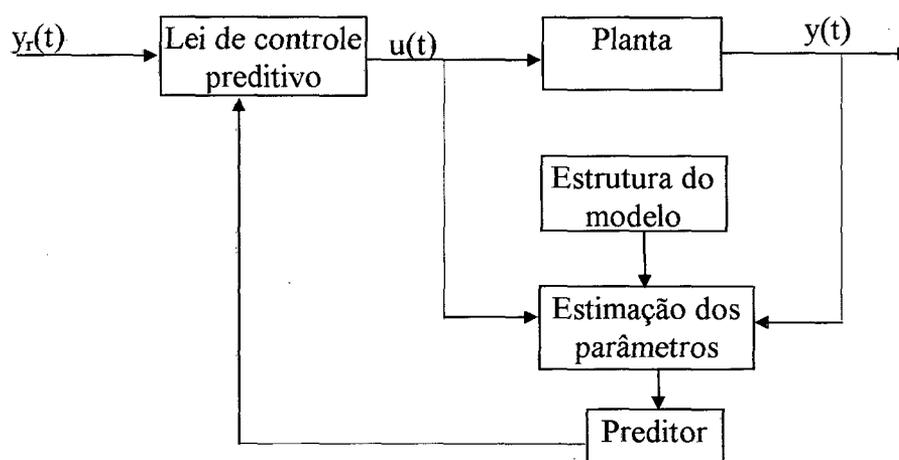


Figura 1.1 - Diagrama esquemático do controle preditivo adaptativo.

1.2 Identificação de sistemas

Observando a estratégia de controle preditivo, percebe-se que a modelagem do processo a ser controlado tem importância fundamental neste tipo de controle. Em geral, têm-se utilizado modelos lineares para a descrição do sistema, pela simplicidade e facilidade de serem tratados. Porém, considerando-se que grande parte dos processos reais são não-lineares, o uso de modelos lineares introduz um certo grau de aproximação. Esta aproximação pode se mostrar aceitável em varias aplicações, contudo há várias vantagens a serem obtidas com a identificação de um modelo não-linear. Uma melhor compreensão das não-linearidades do processo pode possibilitar o projeto de controladores mais eficientes,

como também pode ajudar na seleção de variáveis a serem controladas, na localização de sensores, etc.

Um melhor entendimento das características não-lineares de um sistema complexo pode ser conseguida através da obtenção de seu modelo matemático. Para tanto, pode-se adotar a seguinte abordagem: primeiramente, “divide-se” a planta em subsistemas (eg.: circuitos de atuação, atuadores, sensores, etc.) mais fáceis de serem analisados, e levanta-se o modelo matemático de cada um separadamente. Então, faz-se a integração dos modelos para compor a representação do sistema completo. Entretanto, este tipo de modelagem pode conduzir a equações de ordem elevada com muitos parâmetros, além do fato de que as hipóteses assumidas durante o levantamento do modelo podem ser simplificadoras ou restritivas de maneira que comportamentos essenciais do processo podem não ser capturados (Eskinat *et al.*, 1991).

Uma outra abordagem usualmente utilizada é construir um modelo baseado no comportamento observado para a planta. Este tipo de modelagem empírica é denominada identificação de sistemas. Neste caso o processo é considerado como uma “caixa preta”, onde só se tem acesso aos sinais de entradas e saídas. Com isso, o grande problema da identificação de sistemas é construir um modelo que possa emular os mecanismos internos do sistema, utilizando os dados de entrada e saída. Neste caso, o procedimento usual é selecionar uma estrutura para o modelo com alguns parâmetros desconhecidos e, então, estimá-los. Como último passo deve-se verificar se o modelo obtido é adequado, o que pode ser feito através de índices ou de curvas de validação (Thomson *et al.*, 1996).

1.3 Motivações e objetivos

Na literatura tem-se observado um grande número de trabalhos sobre controladores preditivos adaptativos, em especial para o *GPC*. Além disso, nota-se um crescimento contínuo no número de aplicações destes controladores em processos industriais (Qin e Badgwell, 1996). Esta última talvez seja a melhor justificativa para a utilização dos controladores preditivos, como apontado por Shook *et al.* (1991).

Por outro lado, com o aumento das aplicações, vários autores começaram a sugerir modificações no projeto do *GPC*, visando melhorar seu desempenho. Considerando o fato do *GPC* utilizar um modelo linear para representar processos reais, que geralmente são não-

lineares, várias mudanças foram sugeridas visando um tratamento da não-linearidade do sistema, destacando-se a utilização de modelos não-lineares ou múltiplos modelos ao invés do modelo linear e a utilização de um estimador preditivo com desempenho superior ao *MQR* (Mínimos Quadrados Recursivo).

Baseado nestas idéias, os principais objetivos deste trabalho são:

- realizar um estudo comparativo entre o modelo linear e algumas técnicas de modelagem não-linear utilizadas na literatura;
- comparar o desempenho dos controladores preditivos adaptativos baseados nestas técnicas de modelagem;
- discutir a utilização de um controlador preditivo baseado em múltiplos modelos lineares para o controle de processos não-lineares;
- comparar o desempenho dos estimadores *MQR* e preditivo na identificação e controle linear de sistemas não-lineares;
- aplicar as técnicas apresentadas no processo prático *Fan and Plate*.

1.4 Estrutura da dissertação

Esta dissertação trata dos aspectos de identificação e controle preditivo adaptativo de sistemas não-lineares. Portanto, a divisão do trabalho se baseia no projeto de um controlador adaptativo. Neste caso é necessário determinar a estrutura de modelagem a ser utilizada, o algoritmo de estimação dos parâmetros e a lei de controle a ser aplicada na planta.

No capítulo 2 apresenta-se os algoritmos de estimação utilizados no trabalho. Discute-se as características principais de cada um e mostra-se os passos básicos de cada algoritmo. O capítulo 3 trata das estruturas de modelagem utilizadas: modelo linear, modelo de Hammerstein, modelo bilinear, o modelo de Volterra e múltiplos modelos. Um exemplo de simulação é aplicado a cada uma das estruturas e, então, analisa-se o resultado com respeito ao tempo de processamento e a representatividade do sistema. Controladores preditivos adaptativos, tendo como base os modelos apresentados, estão mostrados no capítulo 4. Apresenta-se os projetos de cada controlador e seus parâmetros de sintonia. Os resultados experimentais, obtidos na identificação e no controle do processo *Fan and Plate*,

estão apresentados no capítulo 5. Finalmente, no capítulo 6 estão apresentadas as conclusões do trabalho e as perspectivas de trabalhos futuros.

2. Algoritmos de Estimação

2.1 Introdução

A aplicação de algoritmos de identificação é interessante para vários propósitos tais como supervisão, rastreamento de parâmetros variantes para controle adaptativo, filtragem, previsão, processamento de sinais, detecção e diagnóstico. A qualidade da estimação é dependente da natureza do ruído, da estrutura do modelo, do tipo de aplicação e da “riqueza” de informação contida nas medidas (Coelho, 1997).

O problema da identificação de sistemas pode ser formulado como a avaliação da estrutura ou dos parâmetros do modelo do sistema, de maneira a representar os aspectos essenciais e o conhecimento do sistema de uma forma adequada (Malik *et al.*, 1991).

Este capítulo trata de algoritmos de identificação de parâmetros em tempo real, especificamente o algoritmo dos mínimos quadrados recursivo e do estimador de múltiplos passos ou preditivo. Ambos os algoritmos consideram a ordem do modelo e o atraso de transporte, d , previamente conhecidos e que as amostras das medidas de entrada e saída estão disponíveis a cada período de amostragem no universo de experimentação.

Existem vários métodos para determinação da ordem do modelo e do atraso de transporte. Pode-se, por exemplo, analisar diferentes estruturas e compará-las com base em certos índices de desempenho, selecionando aquela com melhores resultados. Haber e

Unbehauen (1990) apresentam vários índices desempenho, bem como discutem outros métodos para a obtenção da ordem do modelo e do atraso de transporte a serem utilizados.

2.2 Algoritmo dos mínimos quadrados recursivos

Este algoritmo origina-se do “Princípio dos Mínimos Quadrados”, formulado por Karl Friedrich Gauss, no final do século 18. Neste princípio, é estabelecido que: “O valor mais provável das grandezas desconhecidas é a que minimiza a soma dos quadrados da diferença entre os valores atualmente observados e os valores calculados multiplicados por números que medem o grau de precisão, onde quanto mais precisa a medida, maior a ponderação” (Coelho 1997, Malik *et al.*, 1991).

Atualmente este é um dos algoritmos de estimação mais utilizados para tarefas *on-line*, devido à simplicidade de implementação e ao fato de poder ser aplicado a uma grande variedade de problemas de controle (Malik *et al.*, 1991). Contudo, tem-se observado que o *MQR* pode apresentar alguns problemas em aplicações práticas. Isto pode ser causado por vários fatores como: muitos ou poucos parâmetros selecionados para descrever o sistema adequadamente e a presença de perturbações imprevistas. Diversos autores já propuseram outros tipos de algoritmos baseados no *MQR* visando melhorar seu desempenho, como o mínimos quadrados estendido, máxima verossimilhança, ou então modificações no algoritmo como a introdução de um fator de esquecimento (variável ou constante), reinicialização da matriz de covariância, etc. Vários foram os artigos publicados a este respeito, dentre os quais destaca-se Malik *et al.* (1991) e Shah e Cluett (1991).

O *MQR* minimiza uma função custo dada pela soma dos quadrados dos erros de previsão a um passo a frente, isto é

$$J_{MQR} = \sum_{t=1}^N \left[(y(t) - \hat{y}(t))^2 / (t-1) \right] \quad (2.1)$$

onde $\hat{y}(t)$ representa a previsão do sinal de saída $y(t)$, dadas as informações até o instante $t-1$, e N é o número total de amostras.

Os modelos matemáticos considerados na identificação por *MQR* são modelos de regressão linear, ou seja, lineares com respeito aos parâmetros.

O algoritmo dos mínimos quadrados recursivo pode ser descrito através dos seguintes passos:

- i. medir a saída e entrada do sistema $[y(t+1), u(t-d+1)]$;
- ii. atualizar o vetor de medidas (φ)

$$\varphi^T(t+1) = [-y(t) -y(t-1) \dots u(t-d) u(t-d-1) \dots];$$

- iii. calcular o erro de previsão (ε)

$$\varepsilon(t+1) = y(t+1) - \varphi^T(t+1)\hat{\theta}(t);$$

- iv. calcular o ganho do estimador (K)

$$K(t+1) = \frac{P(t)\varphi(t+1)}{1 + \varphi^T(t+1)P(t)\varphi(t+1)};$$

- v. atualizar o vetor de parâmetros estimados ($\hat{\theta}$)

$$\hat{\theta}(t+1) = \hat{\theta}(t) + K(t+1)\varepsilon(t+1);$$

- vi. atualizar a matriz de covariância (P)

$$P(t+1) = P(t) - K(t+1)[P(t)\varphi(t+1)]^T.$$

Para inicialização do *MQR* deve-se atribuir valores a $\hat{\theta}(0)$ e $P(0)$. Caso nenhuma informação sobre o processo seja conhecida *a priori*, pode-se utilizar $P(0) = mI$, onde m é um valor grande ($\cong 10^3$ ou maior) e I é a matriz identidade, e $\hat{\theta}(0)$ com valores pequenos. Caso contrário, usa-se a informação conhecida para definir $\hat{\theta}(0)$ e valores menores para m .

Através da equação paramétrica do processo

$$y(t) = \varphi^T(t)\theta(t) + e(t) \tag{2.2}$$

onde $e(t)$ representa a perturbação, pode-se destacar uma importante propriedade do estimador de mínimos quadrados: é não-polarizado (os parâmetros estimados convergem para os parâmetros verdadeiros quando o número de interações aumenta) se a perturbação é um ruído branco (média nula e variância σ_e^2) e os sinais $y(t)$, $u(t)$ são estatisticamente independentes de $e(t)$ (Coelho, 1997).

2.3 Estimador preditivo

Este algoritmo foi proposto por Shook *et al.* (1991) baseado na estratégia de controle preditivo. Tradicionalmente, os algoritmos de controle preditivo adaptativo calculam a ação de controle baseados num certo número de previsões futuras da saída do processo. O modelo do processo, que fornece as previsões é usualmente identificado com o *MQR*, onde apenas a previsão de um passo é utilizada. Além disso, observa-se de resultados experimentais e teorias recentes que, freqüentemente, é necessário utilizar um filtro passa-faixa nos dados de entrada do estimador. Tal filtragem é necessária mesmo quando os sinais são “limpos” (pouco ruidosos) para mascarar o efeito das dinâmicas não-modeladas.

Shook *et al.* (1991) ilustra a aplicação do estimador preditivo através de uma simulação, enquanto que Roux *et al.* (1996) implementou o algoritmo em conjunto com o *GPC* no controle de um processo de fermentação.

Este algoritmo minimiza uma função de custo similar à do controlador preditivo generalizado dada por:

$$J_{EP} = \sum_{t=1}^N \sum_{j=1}^{hp} \left[(y(t) - \hat{y}(t))^2 / (t - j) \right] \quad (2.3)$$

Neste caso, o objetivo é minimizar a soma dos quadrados dos erros de previsão sobre um horizonte de predição finito hp . Este algoritmo é denominado de estimador preditivo (*EP*).

Considerando o processo descrito pela equação (2.4),

$$A(q^{-1})y(t) = B(q^{-1})u(t-1) + \frac{T(q^{-1})e(t)}{D(q^{-1})} \quad (2.4)$$

onde q^{-1} é o operador atraso e $A(q^{-1})$, $B(q^{-1})$, $T(q^{-1})$ e $D(q^{-1})$ são polinômios em q^{-1} . Neste trabalho adotou-se $T(q^{-1}) = 1$ e $D(q^{-1}) = \Delta(q^{-1}) = 1 - q^{-1}$. Shook *et al.* (1991) mostrou que, para um processo modelado pela equação (2.4), a função custo descrita em (2.3) é equivalente à do estimador *MQR* acoplada a uma pré-filtragem dos dados. Para a obtenção deste pré-filtro deve-se seguir os seguintes passos:

1. Resolver a seguinte equação polinomial

$$1 = E_j(q^{-1})\hat{A}(q^{-1}) + q^{-j}F_j(q^{-1}), j = 1, \dots, hp \quad (2.5)$$

2. Calcular $L_1(q^{-1})$ através da equação

$$L_1(q^{-1})L_1(q^{-1}) = \left(\sum_{j=1}^{hp} E_j(q^{-1})E_j(q) \right) \quad (2.6)$$

3. Calcular $L(q^{-1}) = L_1(q^{-1})\Delta(q^{-1})$.

Este pré-filtro $L(q^{-1})$ tem característica passa-faixa e é usado para amplificar o sinal nas frequências onde uma boa combinação entre o modelo estimado e o processo são necessárias. Com isso, o modelo da planta pode ser reescrito, do ponto de vista da estimação de parâmetros, na forma (Roux *et al.*, 1996)

$$\begin{aligned} y_f(t) &= \theta^T(t)\phi_f(t) + e_f(t) \\ y_f(t) &= L(q^{-1})y(t) \quad \phi_f(t) = L(q^{-1})\phi(t) \end{aligned} \quad (2.7)$$

onde $\phi(t)$ é o vetor de medidas e $\theta(t)$ é o vetor de parâmetros. Com esta modificação o vetor de parâmetros estimados $\theta(t)$ pode ser atualizado pelo *MQR*. Na figura 2.1, ilustra-se a implementação de cada estimador.

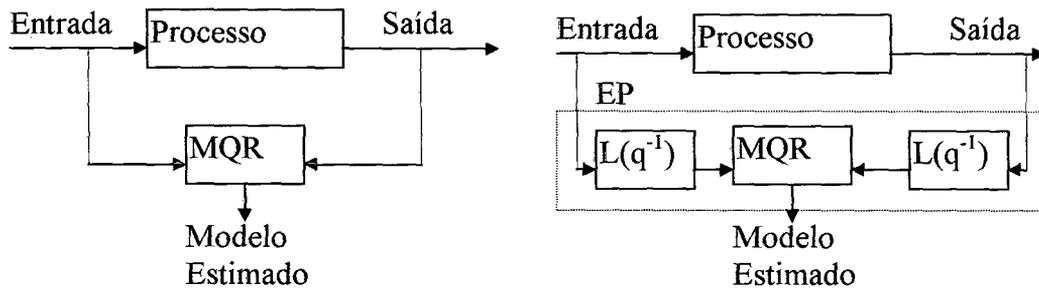


Figura 2.1 - Diagrama esquemático de identificação para o *MQR* e o *EP*.

2.4 Conclusão

Neste capítulo, tratou-se do problema da identificação de sistemas. Foram apresentados os algoritmos dos mínimos quadrados recursivo e do estimador preditivo, mostrando-se os passos básicos para a implementação de cada algoritmo. Embora o primeiro seja mais simples e demande uma carga computacional menor, o *EP* apresenta uma melhor convergência dos parâmetros e uma melhor capacidade para extrair as dinâmicas e características essenciais da planta.

A seleção de um modelo matemático que represente o sistema tem papel fundamental na identificação de sistemas. No capítulo 3 são apresentados vários tipos de modelos que são utilizados na prática.

3. Modelagem de Sistemas

3.1 Introdução

A representação de um sistema a partir de um modelo matemático é fundamental para muitas aplicações. Isto permite que se obtenha informações vitais sobre o sistema, além de possibilitar uma melhor compreensão. Portanto, quanto melhor um modelo aproximar um sistema, melhor é a qualidade e quantidade de informações que pode ser obtida da planta.

Os modelos lineares são muito utilizados na indústria, tendo em vista o fato da teoria de sistemas lineares ser bem desenvolvida. Contudo, na maioria das vezes, os processos reais exibem características que dificultam a aplicação de técnicas de identificação baseadas em modelos lineares e/ou de ordem reduzida. A dificuldade na seleção de modelos matemáticos e ajuste dos parâmetros que sejam adequados são influenciados por diversos fatores, entre os quais: i) conhecimento *a priori* do sistema (linearidade, grau de não-linearidade, atraso de transporte); ii) propriedades do modelo do sistema identificado (complexidade); iii) escolha da medida do erro a ser minimizado; iv) presença de ruídos.

Neste capítulo são apresentadas as estruturas de modelagem utilizadas no trabalho: modelo linear, de Hammerstein, bilinear, de Volterra e múltiplos modelos. Para uma

melhor compreensão destes modelos matemáticos, decidiu-se utilizar um exemplo de simulação, conforme apresentado na figura 3.1.

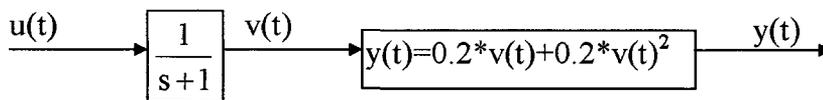


Figura 3.1 - Digrama de blocos do processo.

Discretizando o processo para um período de amostragem de 0.2 segundos e considerando um segurador de ordem zero na malha, obtém-se:

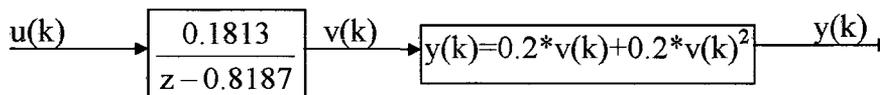


Figura 3.2 - Sistema discretizado.

Na tarefa de identificação do modelo matemático emprega-se um sinal *PRBS* (*Pseudo Random Binary Signal*) para o sinal de entrada com amplitudes de 1 e 4.5, com probabilidade de mudança de amplitude de 50%, coletando-se um total de 1000 amostras. Após cada mudança de amplitude, o sinal de entrada permanece na mesma amplitude por pelo menos 5 períodos de amostragem. Para validação dos modelos obtidos é utilizado um sinal ruído branco com amplitude variando entre 1 e 4.5, num total de 200 amostras. Após cada mudança de amplitude, o sinal permanece no mesmo valor por pelo menos 5 amostras. Para uma avaliação quantitativa utiliza-se um índice de desempenho, apresentado na equação 3.1.

$$R^2 = 1 - \frac{\sum_{i=1}^N (y(i) - \hat{y}(i))^2}{\sum_{i=1}^N (y(i) - \bar{y})^2} \tag{3.1}$$

onde \bar{y} é a média do sinal de saída do processo para N amostras. O critério R^2 com valor igual a 1.0 representa uma combinação perfeita entre o modelo e a planta, nos dados de validação. O coeficiente R^2 entre 0.9 e 1.0 pode ser considerado adequado para várias aplicações.

A determinação da ordem dos modelos e do atraso de transporte foi realizada através da avaliação de modelos com diferentes estruturas, por exemplo representações com dois pólos e um zero, três pólos e dois zeros, selecionando-se aquele com melhor índice R^2 .

Todos os experimentos foram realizados utilizando-se o software MATLAB[®], executando sobre o sistema WINDOWS95[®], e um computador PENTIUM 133Mhz com 24Mb de RAM.

3.2 Modelo linear

Devido ao amadurecimento da teoria de sistemas lineares, este tipo de representação permite uma análise simplificada sobre o comportamento frequencial e temporal do sistema, revelando suas principais características. Estas informações levantadas e o próprio modelo linear podem ser suficientes para a aplicação desejada, descartando, assim, a utilização de técnicas de modelagem complexas. Por isso, a primeira escolha para representar um sistema em geral recai sobre um modelo linear.

Existem vários tipos de representações lineares. Neste trabalho utilizou-se os modelos *Controlled Auto-Regressive Moving-Average - CARMA*, equação (3.2), ou *Controlled Auto-Regressive Integrated Moving-Average - CARIMA*, equação (3.3), isto é:

$$A(z^{-1})y(t) = B(z^{-1})u(t - d) + \xi(t) \quad (3.2)$$

$$A(z^{-1})\Delta y(t) = B(z^{-1})\Delta u(t - d) + \xi(t) \quad (3.3)$$

onde $y(t)$ é a saída, $u(t)$ é a entrada e $\xi(t)$ é a perturbação (de carga ou ruído aleatório com média nula e variância σ^2). Os polinômios $A(z^{-1})$ e $B(z^{-1})$, de ordem na e nb , respectivamente, representam os pólos e zeros em malha aberta, d é o atraso de transporte e $\Delta = (1 - z^{-1})$.

Considerando o exemplo descrito na figura 3.1, levantou-se os seguintes resultados:

- Com o modelo linear *CARMA* com estimador *MQR (ML/MQR)*, com ordens $na = 2$ e $nb = 0$ e $d=1$, tem-se

$$A(z^{-1}) = 1 - 1,0625z^{-1} + 0,2444z^{-2};$$

$$B(z^{-1}) = 0,1663;$$

$$y(t) = 1,0625y(t-1) - 0,2444y(t-2) + 0,1663u(t-1);$$

$$R^2 = 0,7447;$$

Mediu-se, também, o tempo de processamento necessário para a identificação do modelo, neste caso, de 3,51 segundos. Define-se a constante $tmqr = 3,51$ segundos, para servir de base de comparação com os outros algoritmos de estimação.

Nota-se que o modelo obtido apresenta dois pólos enquanto que o sistema possui apenas um pólo. Isto pode ser explicado considerando-se o segundo pólo como uma compensação da dinâmica da não-linearidade.

- Modelo linear *CARMA* com estimador preditivo (*ML/EP*), com $na = 2, nb = 0, d = 1$:

Neste caso, utilizou-se $hp = 2, 4, 6, 8, 10$, com o intuito de investigar a influência do parâmetro hp no tempo de processamento, bem como na qualidade do modelo estimado, obtendo-se:

Tabela 3.1 - Resultados para o EP.

hp	R ²	Tempo (sec.)	Tempo(*tmqr)
2	0,7721	33,78	9,62
4	0,8013	47,34	13,48
6	0,7979	56,41	16,07
8	0,7992	64,42	18,35
10	0,8145	76,45	21,78

Considerando-se o melhor resultado, em função de R^2 , para $hp = 10$, tem-se

$$A(z^{-1}) = 1 - 1,3660z^{-1} + 0,4781z^{-2};$$

$$B(z^{-1}) = 0,0997;$$

$$y(t) = 1,3660y(t-1) - 0,4781y(t-2) + 0,0997u(t-1);$$

Na figura 3.3 estão apresentadas as curvas de validação para os melhores modelos obtidos através do *MLMQR* e *ML/EP*.

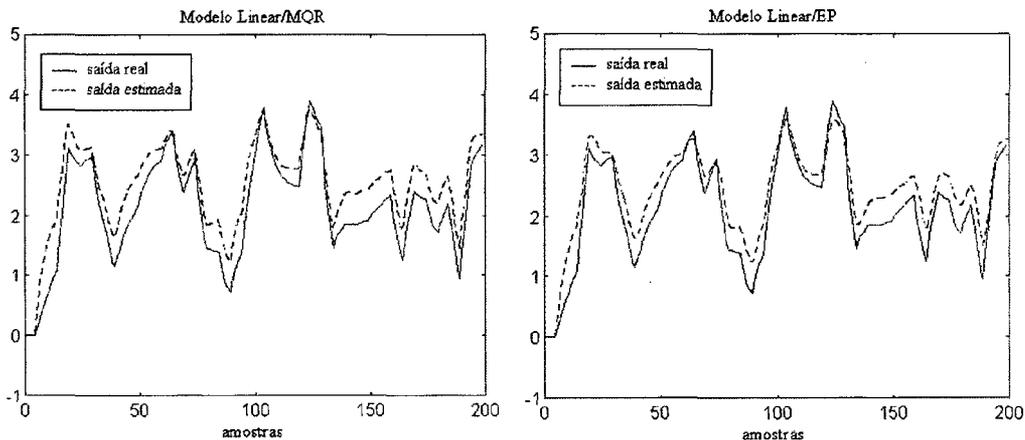


Figura 3.3 - Saída real e dos modelos lineares estimados.

3.3 Modelo de Hammerstein

Uma das abordagens mais usadas na prática para descrição de modelos não-lineares é a descrição do sistema via uma função de Hammerstein (Daniel-Berhe e Unbehauen, 1997). Aparentemente, Narendra e Gallman (1966) foram os primeiros a proporem este tipo de modelagem com fins de controle (Eskinat *et al.*, 1991, Daniel-Berhe e Unbehauen, 1997). Krzyzak e Sasiadek (1997) destacam a aplicação do modelo de Hammerstein no cancelamento adaptativo de ruído, identificação de sistemas biológicos, processamento de imagens e controle adaptativo. No caso, exemplos da utilização do modelo de Hammerstein na identificação de sistemas não-lineares são apresentados por: Krzyzak e Sasiadek (1997) na identificação de um componente de atrito num sistema robótico; Eskinat *et al.* (1991) na identificação de um sistema trocador de calor e de uma coluna de destilação; e Daniel-Berhe e Unbehauen (1997) em exemplos de simulações.

Neste caso, o modelo se compõe de uma não-linearidade estática em série com uma dinâmica linear, figura 3.4.

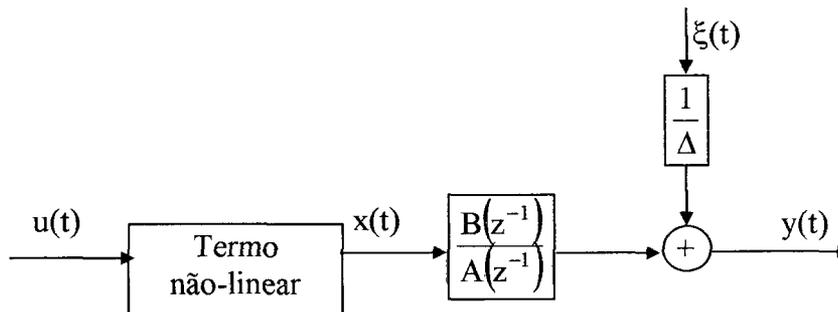


Figura 3.4 - Esquema de modelagem de Hammerstein do sistema.

Para representar a dinâmica linear, utiliza-se o modelo *CARIMA*. Logo, a planta a ser controlada pode ser descrita pelo seguinte modelo discreto:

$$A(z^{-1})\Delta y(t) = B(z^{-1})\Delta x(t - d) + \xi(t) \quad (3.4)$$

onde a variável auxiliar $x(t)$ é o elemento não-linear. A estrutura do bloco não-linear pode variar de funções exponenciais (estrutura clássica) a redes neurais artificiais (estruturas avançadas) (Fruzzetti *et al.*, 1996). Neste trabalho, utilizou-se uma série de potências para descrever este bloco, ou seja:

$$x(t) = \sum_{i=1}^{n_y} \gamma_i u^i(t) \quad (3.5)$$

e sendo γ_i os coeficientes do modelo não-linear. Observa-se que o modelo adotado apresenta linearidade nos parâmetros e, portanto, podem ser estimados através do algoritmo dos mínimos quadrados recursivo, com algumas mudanças (Eskinat *et al.*, 1991). É interessante ressaltar que existe uma certa redundância de parâmetros; dessa forma, o coeficiente γ_1 é usualmente arbitrado em 1 (um). Neste caso de projeto, o número de parâmetros estimados, em geral, é maior que no modelo linear.

Aplicando o modelo de Hammerstein (MH) ao exemplo descrito em 3.1, obteve-se como melhor resultado, com $na = 1$, $nb = 0$, $d = 1$ e $n_\gamma = 2$:

$$A(z^{-1}) = 1 - 0,8003z^{-1};$$

$$B(z^{-1}) = 0,0697;$$

$$\gamma_1 = 1 \quad \gamma_2 = 0,3956;$$

$$y(t) = 0,8003y(t-1) + 0,0697u(t-1) + 0,028u(t-1)^2;$$

$$R^2 = 0,9778;$$

tempo de processamento = 5,93 segundos.

Na figura 3.5 ilustra-se o aspecto de validação do modelo de Hammerstein.

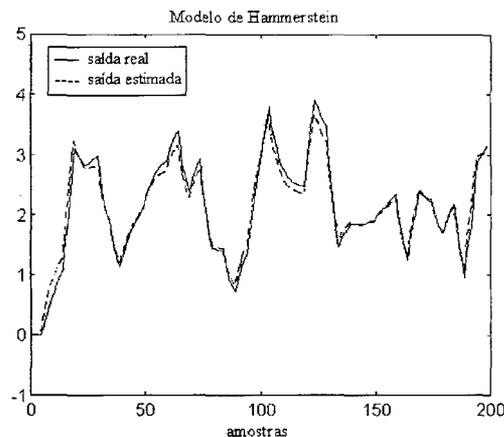


Figura 3.5 - Curva de validação para o modelo de Hammerstein.

3.4 Modelo bilinear

O modelo bilinear (Mackay *et al.*, 1996) baseia-se num modelo linear tipo *CARMA* acrescido de termos não-lineares compostos de produtos entre a entrada e a saída como é descrito na equação:

$$A(z^{-1})y(t) = B(z^{-1})u(t-d) + \sum_{i=0}^{ny} \sum_{j=0}^{nu} c_{ij}y(t-d-i)u(t-d-j) + \xi(t) \quad (3.6)$$

onde c_{ij} são os coeficientes do modelo não-linear e ny e nu representam o grau da não-linearidade. De fato, caso a entrada possa ser considerada um sinal conhecido, este tipo de modelo pode ser visto como um sistema linear variante no tempo. Neste caso o número de parâmetros estimados, em geral, é maior que no modelo de Hammerstein. Como o modelo bilinear é linear com respeito aos parâmetros, pode-se utilizar o *MQR* para estimá-los.

Uma justificativa para o uso do modelo bilinear reside no fato de que vários processos industriais apresentam características bilineares, como processos de fermentação, reatores nucleares e reatores químicos (Mackay *et al.*, 1996). Isto permite uma melhor aproximação da realidade e, portanto, o modelo bilinear possuirá uma maior aproximação na faixa de validade (pontos de operação) do que o modelo linear.

Na literatura, tanto Fnaiech e Ljung (1987) e Svoronos *et al.* (1981) tratam da estimação dos parâmetros do modelo bilinear apresentando resultados baseados em simulações. Sommer (1994) trata do controle preditivo por modelo bilinear aplicando-o em um exemplo simulado. Mackay *et al.* (1996) aplica o modelo bilinear no controle *MBPC* (*Model Based Predictive Control*) de um tanque reator.

Aplicando o modelo bilinear (*MB*) ao exemplo, foram obtidos os seguintes resultados:

$$\begin{aligned} A(z^{-1}) &= 1 - 0,6939z^{-1}; \\ B(z^{-1}) &= 0,1417; \\ c_{00} &= 0,0414; \\ y(t) &= 0,6939y(t-1) + 0,1417u(t-1) + 0,0414y(t-1)*u(t-1); \\ R^2 &= 0,9887; \\ \text{tempo de processamento} &= 3,41 \text{ segundos.} \end{aligned}$$

A figura 3.6 ilustra a validação do modelo bilinear.

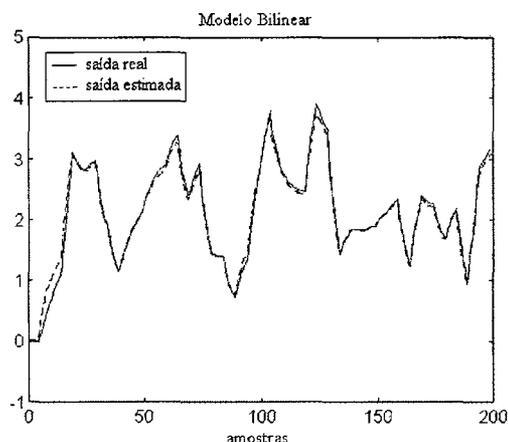


Figura 3.6 - Comparação entre a saída real e estimada do modelo bilinear.

3.5 Modelo de Volterra

Este modelo baseia-se na série de Volterra (Roux *et al.*, 1996) sendo que, neste caso, trunca-se a série nos termos de segunda ordem e com memória finita. A aproximação por série de Volterra para sistemas não-lineares pode ser vista como uma generalização da representação por resposta ao impulso de sistemas lineares. Este tipo de representação apresenta melhores resultados para sistemas estáveis em malha aberta (Bars e Haber, 1991).

O modelo de Volterra pode ser descrito como:

$$y(t) = h_0 + \sum_{i=1}^{nh} h_{1i} u(t-d-i) + \sum_{i=1}^{nh} \sum_{j=i}^{nh} h_{2ij} u(t-d-i) u(t-d-j) + \xi(t) \quad (3.7)$$

onde os parâmetros h_0 , h_{1i} e h_{2ij} são os coeficientes do modelo e nh representa a memória. O número de parâmetros a serem estimados é maior que no modelo bilinear. Como o modelo de Volterra, equação (3.7), é linear com respeito aos parâmetros, o algoritmo de estimação dos *MQR* pode ser implementado. O número de termos do modelo de Volterra pode ser calculado em função da memória nh , equação (3.8).

$$n^\circ \text{ de termos} = \frac{(nh+1)(nh+2)}{2} \quad (3.8)$$

Aplicando o modelo de Volterra (MV) ao exemplo, pode-se notar que a aproximação do modelo é melhor quanto maior o valor da memória nh . Para $nh = 15$, obteve-se $R^2 = 0,9962$, significando um combinação praticamente perfeita entre o modelo e a saída real nos dados de validação, porém este modelo possui 136 termos, com termos em $u(t-15)$, além de um tempo de processamento de 164,73 segundos. Para $nh = 4$, obteve-se um $R^2 = 0,7839$, próximo dos modelos lineares, contudo, neste caso, tem-se apenas 15 termos e um tempo de processamento de 8,07 segundos. O modelo obtido para $nh = 4$ foi

$$h_0 = 0, h_1 = [-0,1360 \quad -0,0273 \quad 0,0256 \quad 0,9355]$$

$$h_2 = \begin{bmatrix} 0,0448 & 0,0142 & 0,0077 & 0,019 \\ 0 & 0,0136 & 0,0072 & 0,0185 \\ 0 & 0 & 0,0038 & 0,0151 \\ 0 & 0 & 0 & -0,1266 \end{bmatrix}$$

$$y(t) = -0,136u(t-1) - 0,0273u(t-2) + 0,0256u(t-3) + 0,9355u(t-4) + 0,0448u(t-1)^2 + 0,0142u(t-1)u(t-2) + 0,0077u(t-1)u(t-3) + 0,019u(t-1)u(t-4) + 0,0136u(t-2)^2 + 0,0072u(t-2)u(t-3) + 0,0185u(t-2)u(t-4) + 0,0038u(t-3)^2 + 0,0151u(t-3)u(t-4) - 0,1266u(t-4)^2$$

A figura 3.7 ilustra a característica de resposta do modelo de Volterra.

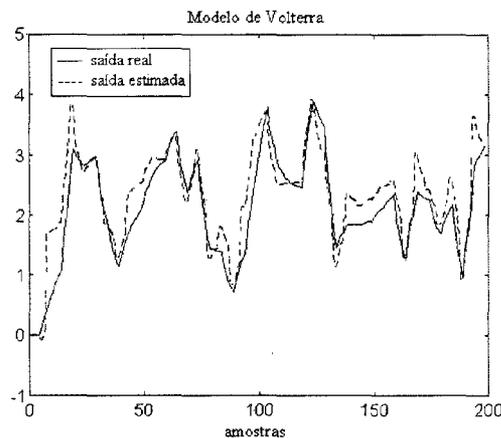


Figura 3.7 - Validação para o modelo de Volterra com $nh = 4$.

3.6 Múltiplos Modelos

O conceito de múltiplos modelos já foi utilizado por Lainiotis (1976) e Athans *et al.* (1977), no caso, para melhorar a precisão da estimação de estados em problemas de controle utilizando vários filtros de Kalman. Esta idéia também já foi aplicada no controle

de aeronaves ou para o controle de sistemas em medicina (Narendra *et al.*, 1995). Hecker *et al.* (1994) utiliza um conceito de estimadores recursivos em paralelo, bastante semelhante ao de múltiplos modelos, para o controle de um processo *benchmark* variante no tempo.

A estratégia de identificação por múltiplos modelos apresentada baseia-se na idéia de se utilizar um conjunto de modelos para descrever uma mesma planta e continuamente selecionando-se aquele com melhor aproximação. Portanto, dois pontos vitais para este tipo de identificação são: a escolha do conjunto de modelos para descrever a planta e o esquema de chaveamento entre os modelos.

O critério de seleção entre os modelos consiste em monitorar um índice de desempenho $J_j(t)$, baseado no erro de identificação e_j para cada modelo I_j e, então, chavear para o controlador correspondente o modelo com menor valor de $J_j(t)$. A razão para tal estratégia reside no fato de que um erro de identificação pequeno leva a um erro de rastreamento pequeno (Narendra *et al.*, 1995). A seleção do índice baseia-se na observação empírica de que tanto as medidas instantâneas quanto as medidas passadas são necessárias para um estimador confiável. Uma seleção possível para o índice é:

$$J_j(t) = \alpha e_j^2(t) + \beta J_j(t-1) \quad (3.9)$$

onde α e β são parâmetros de projeto. Para prevenir um chaveamento arbitrariamente rápido entre os modelos, decidiu-se utilizar um tempo mínimo, t_{min} , para a manutenção de um modelo chaveado (Narendra e Balakrishnan, 1994).

Para o conjunto de modelos a serem selecionados pode-se adotar tanto modelos fixos como adaptativos. O uso de modelos fixos é computacionalmente mais eficiente, tendo em vista que apenas as saídas de cada modelo devem ser calculadas. No caso adaptativo, deve-se também atualizar o vetor de parâmetros $\theta_j(t)$, o que introduz um esforço computacional significativo. Além disso, se somente forem utilizados modelos adaptativos todos convergirão para uma vizinhança dos parâmetros do processo θ^* . Caso θ^* varie abruptamente, todos os outros parâmetros $\theta_j(t)$ terão de ser reinicializados para suas localizações originais de forma que possam rapidamente identificar o novo valor de θ^* . Este problema não ocorre com modelos fixos. Contudo, quando implementa-se apenas um modelo adaptativo assegura-se uma perfeita precisão assintoticamente, mas um grande número de modelos fixos se faz necessário para obter-se a precisão desejada. Através da

utilização de um modelo adaptativo em conjunto com N modelos fixos, consegue-se pequenos erros no transiente e erro nulo no regime permanente (Narenda *et al.*, 1997).

Neste trabalho utilizou-se esta estratégia apenas na tarefa de controle de sistemas e, portanto, não se aplicou esta técnica ao exemplo apresentado na seção 3.1.

3.7 Conclusão

Neste capítulo, foram apresentadas as estruturas de modelagem lineares e não-lineares implementadas no trabalho, destacando-se as características principais de cada método. Utilizou-se também um exemplo numérico para ilustrar a aplicação de cada técnica de modo a estabelecer um grau de comparação em termos de precisão e carga computacional.

Através deste exemplo, verificou-se que o estimador preditivo obteve um desempenho superior ao *MQR*, porém com um maior esforço computacional. Observa-se que os métodos de modelagem não-lineares obtiveram um melhor desempenho frente aos modelos lineares. Dentre estes, destacou-se o modelo bilinear que obteve excelentes resultados com um esforço computacional equivalente ao do *MQR*. Na tabela 3.2, apresenta-se as melhores respostas para cada tipo de modelo implementado.

Tabela 3.2 - Resultados de modelagem linear e não-linear

Modelo	R^2	tempo(sec.)	Tempo (tmqr)
ML/MQR	0,7447	3,51	1
ML/EP	0,8145	76,45	21,78
MH	0,9778	5,93	1,69
MB	0,9887	3,41	0,97
MV	0,9962	164,73	46,93

Uma das grandes aplicações da modelagem de sistemas reside no controle de processos. No capítulo 4, será apresentado estratégias de controle preditivo adaptativo que utilizam estas estruturas de modelagem.

4. Controle Preditivo

4.1 Introdução

Há pouco mais de 30 anos atrás, o controle por computador foi introduzido no meio industrial e, desde então, diversos trabalhos de pesquisas têm sido conduzidos nos meios acadêmicos e industriais nesta área. Dado ao grande desenvolvimento da informática, atualmente é possível a implementação de algoritmos de controle complexos sem que haja um aumento considerável no custo de projeto.

A estratégia de controle preditivo, geralmente, baseia-se numa combinação de um preditor, uma função custo, um algoritmo capaz de gerar a ação de controle que minimiza uma função de custo e um esquema de identificação paramétrica. Para um grande número de processos, pode-se utilizar um modelo linear e estimar seus parâmetros com o uso de um algoritmo como o mínimos quadrados recursivo, sendo que as não-linearidades fracas podem ser tratadas pelo estimador e, conseqüentemente, pelo controlador, para o processo sob avaliação. Porém, na presença de fortes não-linearidades, o desempenho do controlador torna-se insatisfatório, inferior à dinâmica esperada pelo operador, como se a planta fosse realmente linear (Zhu *et al.*, 1991). Para melhorar o desempenho do controlador pode-se usar várias abordagens como utilizar um modelo não-linear para a planta, por exemplo o modelo de Hammerstein, ou utilizar múltiplos modelos para descrever a planta.

Neste capítulo, as abordagens linear e não-linear são exploradas utilizando-se os modelos apresentados no capítulo 3. Todos os controladores implementados se baseiam no projeto do *GPC*.

4.2 Controlador *GPC*

Neste trabalho, utilizou-se o controlador preditivo generalizado conforme apresentado por Clarke e Mohtadi (1989). Existem diversas aplicações do *GPC* na literatura, dentre as quais cita-se: Hunt *et al.* (1998) para o controle do momento na junta do joelho em paraplégicos, Aymes e Bordeneuve-Guibé (1996) para o controle de um avião de caça e Geng e Geary (1998) utilizam o *GPC* para o controle de temperatura.

O *GPC* minimiza a seguinte função custo (4.1), sujeita a restrição (4.2):

$$J_{GPC} = \left\{ \sum_{j=1}^{HY} [y(t+j) - y_r(t+j)]^2 + \Gamma \sum_{j=1}^{Hu} [\Delta u(t+j-1)]^2 \right\} \quad (4.1)$$

$$\Delta(z^{-1})u(t+j-1) = 0, \quad j \geq Hu \quad (4.2)$$

onde $y_r(t)$ é o sinal de referência, HY e Hu denotam os horizontes de previsão da saída e do controle, respectivamente, e Γ representa a ponderação do controle. Os horizontes de previsão e a ponderação do controle são os parâmetros de sintonia de controle. O projeto do controlador *GPC* utiliza o modelo *CARIMA* para representar o sistema.

Seja a seguinte identidade polinomial

$$1 = A(z^{-1})\Delta E_j(z^{-1}) + z^{-j}F_j(z^{-1}), \quad j = 1, \dots, HY \quad (4.3)$$

onde

$$E_j(z^{-1}) = 1 + e_1 z^{-1} + \dots + e_{ne} z^{-ne}$$

$$F_j(z^{-1}) = f_0 + f_1 z^{-1} + \dots + f_{nf} z^{-nf}$$

$$ne = j-1$$

$$nf = na$$

Multiplicando a equação do modelo do sistema (3.3) por $q^j E_j(q^{-1})$, obtém-se

$$E_j(z^{-1})A(z^{-1})\Delta y(t+j) = E_j(z^{-1})B(z^{-1})\Delta u(t+j-d) + E_j(z^{-1})\xi(t+j) \quad (4.4)$$

Substituindo a equação (4.3) em (4.4), tem-se que

$$y(t+j) = E_j(z^{-1})B(z^{-1})\Delta u(t+j-d) + F_j(z^{-1})y(t) + E_j(z^{-1})\xi(t+j) \quad (4.5)$$

e reescreve-se a equação (4.5) como:

$$y(t+j) = F_j(z^{-1})y(t) + G'_j(z^{-1})\Delta u(t+j-d) + E_j(z^{-1})\xi(t+j) \quad (4.6)$$

com

$$G'_j(z^{-1}) = E_j(z^{-1})B(z^{-1})$$

Como o ruído está decorrelacionado dos sinais mensuráveis no instante t , $y(t)$ e $u(t)$, tem-se que a melhor previsão possível para a saída é calculada por

$$\hat{y}(t+j) = F_j(z^{-1})y(t) + G'_j(z^{-1})\Delta u(t+j-d) \quad (4.7)$$

Considerando a seguinte identidade polinomial

$$G'_j(z^{-1}) = G_j(z^{-1}) + z^{-j}\bar{G}_j(z^{-1}) \quad (4.8)$$

e utilizando-a na equação (4.7), obtém-se

$$\hat{y}(t+j) = F_j(z^{-1})y(t) + \bar{G}_j(z^{-1})\Delta u(t-d) + G_j(z^{-1})\Delta u(t+j-d) \quad (4.9)$$

|← informações disponíveis →| |← futuro →|
no instante t

onde os elementos g_i de $G_j(z^{-1})$ são calculados a partir da resposta ao degrau do modelo do processo, e correspondem aos termos da divisão de $B(z^{-1})/A(z^{-1})\Delta$. A partir da equação (4.9), pode-se caracterizar a previsão da resposta livre do sistema (com base na informação disponível no instante t), como sendo:

$$\hat{y}(t + j/t) = F_j(z^{-1})y(t) + \bar{G}_j(z^{-1})\Delta u(t - d) \quad (4.10)$$

Considere o vetor f , formado a partir das previsões da resposta livre,

$$f = [\hat{y}(t+1/t) \quad \hat{y}(t+2/t) \quad \dots \quad \hat{y}(t+HY/t)]^T \quad (4.11)$$

e o vetor do controle incremental futuro

$$\Delta U = [\Delta u(t) \quad \Delta u(t+1) \quad \dots \quad \Delta u(t+Hu-1)]^T \quad (4.12)$$

A partir destas definições, a equação (4.9) pode ser representada na forma vetorial

$$\hat{Y} = G\Delta U + f \quad (4.13)$$

onde

$$\hat{Y} = [\hat{y}(t+1) \quad \hat{y}(t+2) \quad \dots \quad \hat{y}(t+HY)]^T$$

$$G = \begin{bmatrix} g_0 & 0 & \dots & 0 \\ g_1 & g_0 & \dots & 0 \\ \vdots & \ddots & \ddots & \vdots \\ \vdots & \ddots & \ddots & g_0 \\ \vdots & \ddots & \ddots & \vdots \\ g_{HY-1} & g_{HY-2} & \dots & g_{HY-Hu-1} \end{bmatrix}$$

Assim, a função custo do *GPC*, equação (4.1), também pode ser representada na forma vetorial, ou seja:

$$J_{GPC} = [\hat{Y} - Y_r]^T [\hat{Y} - Y_r] + \Gamma \Delta U^T \Delta U \quad (4.14)$$

onde

$$Y_r = [y_r(t+1) \quad y_r(t+2) \quad \dots \quad y_r(t+HY)]^T \quad (4.15)$$

Minimizando a função custo apresentada em (4.14), obtém-se a lei de controle

$$\Delta U = [G^T G + \Gamma I]^{-1} G^T [Y_r - f] \quad (4.16)$$

Na prática, apenas o primeiro sinal de controle é aplicado e, a cada iteração, resolve-se um novo problema de minimização. Portanto, a ação de controle a ser aplicada na planta é calculada por:

$$u(t) = u(t-1) + \Delta u(t) \quad (4.15)$$

4.3 Controle preditivo baseado no modelo de Hammerstein

Na literatura, pode-se citar como exemplos da aplicação deste controlador os trabalhos de Roux *et al.* (1996) para o controle de um processo de fermentação e Zhu *et al.* (1991), Fruzzetti *et al.* (1997) e Patwardhan *et al.* (1998) em aplicações de controle de pH.

Neste caso, o controlador *GPC* é projetado considerando apenas a parte linear do modelo apresentado na equação (3.4). O procedimento de projeto é idêntico ao apresentado na seção 4.2 bastando substituir $u(t)$ por $x(t)$. Como adotou-se uma não-linearidade descrita por um polinômio, como apresentado na equação (3.5), agora deve-se utilizar um algoritmo para determinar a raiz deste polinômio e, assim, determinar o valor de $u(t)$ a ser aplicado na planta. Neste trabalho, utilizou-se o método de Newton-Raphson para o cálculo da raiz como indicado em Zhu *et al.* (1991). Pode ser notado pela equação (3.5) que:

$$x(t) = \phi\{u(t)\} \quad (4.16)$$

onde $\phi\{\cdot\}$ denota o operador funcional; neste caso é uma função polinomial. Portanto, pelo método Newton-Raphson deve-se procurar a raiz da equação (4.16) de maneira iterativa, através da seguinte equação:

$$u_{n+1} = u_n - \frac{[\phi\{u_n\} - x(t)]}{\phi'\{u_n\}} \quad (4.17)$$

onde n denota a ordem da iteração e $\phi'\{u_n\} = \frac{d\phi(t)}{du(t)}\{u_n\}$. Com isso, quando $\phi\{u_n\} \cong x(t)$, toma-se $u(t) = u_n$. Como valor inicial para este método seleciona-se $u_0 = u(t-1)$. Para informações adicionais sobre a implementação deste algoritmo ver Zhu *et al.* (1991).

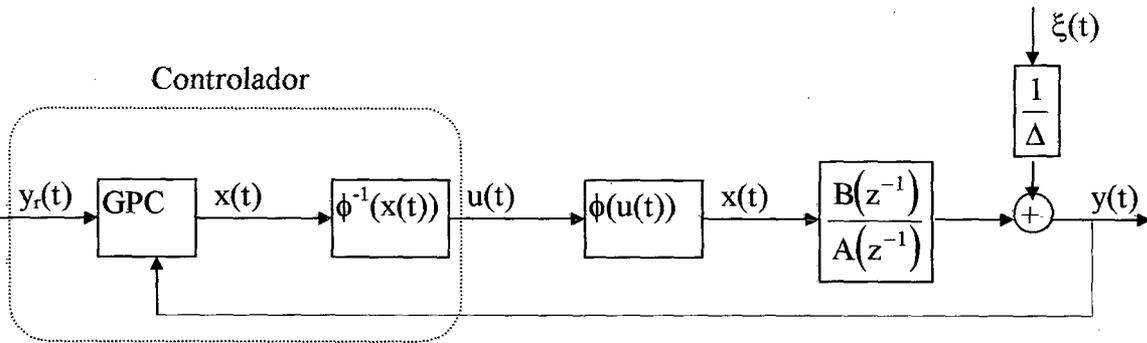


Figura 4.1 - Esquema do controlador GPC com o modelo de Hammerstein.

4.4 Controlador preditivo baseado no modelo de Volterra

Este controlador minimiza a mesma função custo do controlador *GPC*. Contudo, neste caso, utiliza-se o modelo de Volterra, como apresentado na seção 3.5 para a previsão da saída. Mudanças significativas são necessárias tanto em relação ao *GPC* quanto ao projeto final do controlador. Utiliza-se o mesmo formalismo apresentado por Roux *et al.* (1996). Reescrevendo a equação (4.14) para o modelo de Volterra, obtém-se:

$$J_{GPC} = E\left(\left(\tilde{H}_2 u^2 + \tilde{H}_1(u)u + m\right)^T \left(\tilde{H}_2 u^2 + \tilde{H}_1(u)u + m\right) + \Gamma(\Delta u)^T (\Delta u)\right) \quad (4.18)$$

onde \check{H}_2 e \check{H}_1 são matrizes de ordem $HY \times Hu$, u representa o vetor de entradas futuras de ordem Hu e m é um vetor que contém os dados disponíveis até o instante atual, t , calculado pela equação (4.19).

$$m(t+j) = h_0 + \sum_{i=j}^{nh} h_{1i} u(t+j-i-1) + \sum_{i=j}^{nh} \sum_{l=i}^{nh} h_{2il} u(t-i+j-1) u(t-l+j-1) - y_r(t+j) \quad (4.19)$$

A minimização da função custo apresentada na equação (4.18) conduz a uma equação vetorial de terceira ordem. Considerando $Hu=1$, minimiza-se o esforço computacional e os cálculos ficam facilitados, isto é, as matrizes se transformam em vetores e o procedimento de otimização se torna simples. Assim, deriva-se a seguinte equação para a ação de controle:

$$\begin{aligned} & \left(2 \sum_{j=1}^{HY} H_{2j}^2 \right) u^3(t) + \left(3 \sum_{j=1}^{HY} H_{1j} H_{2j} \right) u^2(t) + \left(\sum_{j=1}^{HY} (H_{1j}^2 + H_{2j} m(t+j)) + \Gamma \right) u(t) \\ & + \left(\sum_{j=1}^{HY} H_{1j} m(t+j) - \Gamma u(t-1) \right) = 0 \end{aligned} \quad (4.20)$$

Esta equação é bastante similar à equação não-linear a ser resolvida no caso do controlador baseado no modelo de Hammerstein e, portanto, pode-se aplicar o método de Newton-Raphson em (4.20), obtendo-se o valor de $u(t)$ a ser aplicado na planta. Os valores de H_{1j} e H_{2j} podem ser obtidos através das equações (4.21) e (4.22).

$$H_{1j} = \sum_{i=1}^j h_{1i} + \sum_{l=j+1}^{nh} \left(\sum_{i=1}^j h_{2il} \right) u(t-1+j) \quad (4.21)$$

$$H_{2j} = \sum_{i=1}^j \sum_{l=i}^j h_{2il} \quad (4.22)$$

Em Bars e Haber (1991) é possível obter maiores detalhes do projeto do controlador. Sommer (1994) e Bars e Haber (1991) utilizaram no controle adaptativo através de

processos simulados. Roux *et al.* (1996) aplicou no controle de um processo de fermentação.

4.5 Controlador preditivo não-linear

Apresentado por Morningred *et al.* (1992), para o controle de um reator, o controlador baseia-se no modelo descrito pela equação (4.23).

$$y(t) = F[y(t-1), u(t-d-1), \mathbf{Z}(t-1), \mathbf{M}(t-1)] \quad (4.23)$$

onde

$$\begin{aligned} \mathbf{y}(t-1) &= [y(t-1), y(t-2), \dots, y(t-n_y)]^T; \\ \mathbf{u}(t-d-1) &= [u(t-d-1), u(t-d-2), \dots, u(t-d-n_u)]^T; \\ \mathbf{Z}(t-1) &= [z(t-1), z(t-2), \dots, z(t-n_z)]; \\ \mathbf{M}(t-1) &= [m(t-1), m(t-2), \dots, m(t-n_m)]; \end{aligned}$$

O sinal $y(t)$ representa a saída controlada, $u(t)$ é a entrada a ser manipulada, $z(t)$ é um vetor com as outras saídas do processo, $m(t)$ é um vetor contendo as outras entradas do processo e F é uma função não-linear genérica. Este modelo é denominado de *NARMAX* (Nonlinear Auto-Regressive Moving Average with Exogenous Inputs) e pode ser utilizado para representar qualquer outro modelo já apresentado no capítulo 3. O *NARMAX* é linear nos parâmetros e pode ser estimado utilizando um algoritmo como o *MQR*.

O projeto do controlador assume que uma dinâmica linear pode ser separada do modelo *NARMAX* apresentado em (4.23), da seguinte forma:

$$\begin{aligned} F[y(t-1), u(t-d-1), \mathbf{Z}(t-1), \mathbf{M}(t-1)] &= q[1 - A(q^{-1})]y(t-1) + \\ &G[y(t-1), u(t-d-1), \mathbf{Z}(t-1), \mathbf{M}(t-1)] \quad (4.24) \end{aligned}$$

onde $A(z^{-1})$ representa um polinômio em z^{-1} e G representa uma função não-linear genérica. Os pólos de $A(z^{-1})$ devem ser estáveis. Utilizando a estratégia de linearização apresentada

por Hunt *et al.* (1983), define-se uma nova variável, $v(t-d-1)$, para representar a não linearidade da equação (4.24), ou seja:

$$v(t-d-1) \equiv G[y(t-1), u(t-d-1), Z(t-1), M(t-1)] \quad (4.25)$$

Assim, utilizando as equações (4.23), (4.24) e (4.25), resulta:

$$\begin{aligned} y(t) &= z[1 - A(z^{-1})]y(t-1) + v(t-d-1) \\ A(z^{-1})y(t) &= v(t-d-1) \end{aligned} \quad (4.26)$$

e tem-se um sistema linear em $v(t-d-1)$. Considerando-se agora o projeto do controlador *GPC*, descrito na seção 4.2, para o sistema da equação (4.26), obtém-se o valor de $v(t)$, e, portanto, pode-se calcular o valor de $u(t)$ a ser aplicado na planta através da equação (4.25).

A grande dificuldade de projeto desta estratégia de controle é a necessidade de uma representação perfeita do sistema. Neste trabalho, utilizou-se este projeto de controle para o modelo bilinear. Isto porque o cálculo da previsão da saída para este tipo de modelo é extremamente complexa e nenhuma fórmula analítica, como a equação de Diofantine (equação (4.3)), pode ser aplicada a este tipo de modelo, como mostrou Sommer (1994).

4.6 Controle preditivo utilizando múltiplos modelos

Métodos de controle adaptativo direto e indireto já são bem conhecidos. Em geral, algoritmos baseados nestes métodos apresentam problemas de rastreamento de referência durante o transiente e na inicialização do sistema (Narendra e Balakrishnan, 1994). Uma possível explicação para este problema reside no fato de que qualquer sistema complexo, em geral, opera em diferentes ambientes (variações paramétricas, perturbações externas). Quando ocorre uma mudança no ambiente, as características de entrada e saída do processo também podem mudar de forma rápida ou até descontinuamente. Caso se utilize apenas um algoritmo de identificação do sistema, este terá que se adaptar ao novo ambiente antes que a ação de controle apropriada possa ser tomada. Neste caso, uma possível lentidão na

adaptação pode levar a grandes erros no transiente. Uma solução para este problema é a utilização de múltiplos modelos, tanto para identificar os diferentes ambientes de trabalho como para controlá-los de forma eficiente e segura.

Neste trabalho, optou-se por utilizar modelos lineares do tipo *CARIMA* para descrição da planta e o controlador *GPC*, como ilustrado na figura 4.2.

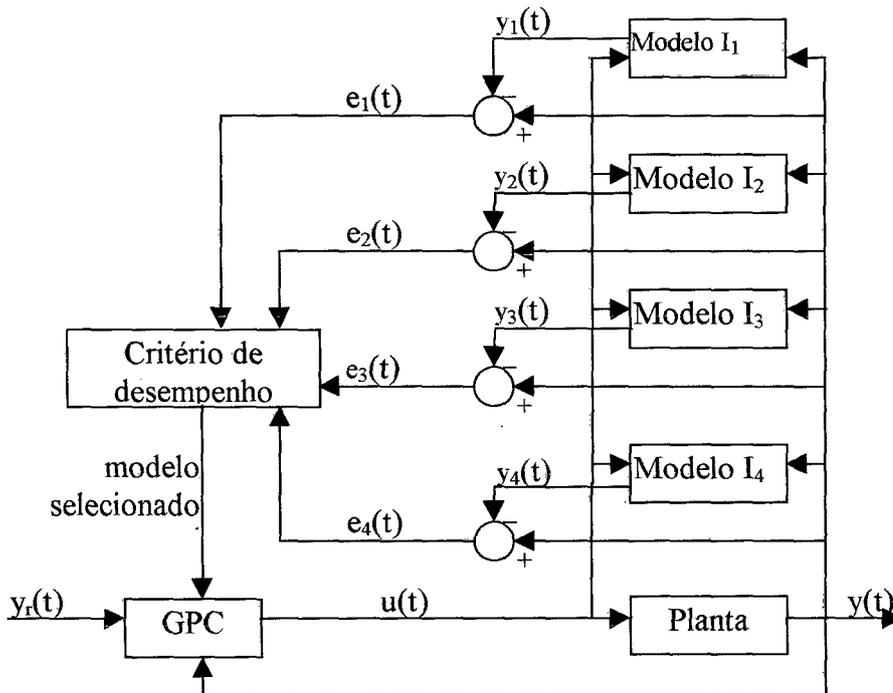


Figura 4.2 - Esquema de controle utilizando múltiplos modelos.

onde $e_j(t) = y(t) - y_j(t)$ para $j = 1, \dots, 4$. Os índices I_1, I_2 e I_3 são obtidos dos modelos fixos enquanto I_4 é obtido do modelo adaptativo.

4.7 Conclusão

Neste capítulo, foram apresentadas diferentes técnicas de projeto de controle, todas baseadas no *GPC*. Primeiramente, fez-se uma descrição detalhada do projeto do controlador. As outras estratégias de controle apresentadas visam melhorar o desempenho deste controlador frente a sistemas não-lineares, e, dessa forma, utilizam representações não-lineares ou vários modelos lineares para a modelagem do sistema. A principal razão

para tais abordagens reside no fato de que um erro de identificação pequeno leva a um erro de rastreamento pequeno.

No capítulo 5, estas estratégias de controle são aplicadas num processo prático *Fan and Plate*, buscando-se, assim, comparar o desempenho de cada controlador.

5. Resultados Experimentais

5.1 Introdução

A experimentação prática tem papel fundamental no desenvolvimento de projetos, tanto em controle como em qualquer outra atividade. Simulações por computadores são ferramentas poderosas no auxílio ao desenvolvimento do projeto, porém nada substitui a aplicação prática como teste final do controlador.

Isto é um fato bem conhecido por todos e, portanto, muitas universidades apresentam um laboratório com processos reais para estimular o aprendizado e preparar o aluno para problemas que poderá enfrentar mais tarde na vida profissional e que só podem ser percebidos através da prática. Contudo, as universidades em geral contam com um orçamento reduzido o que dificulta a aquisição de kits para ensino e pesquisa na área de controle de processos industriais.

Uma possível solução para tal problema é a manufatura de processos de baixo custo pelo próprio laboratório. O Laboratório de Controle de Processos (*LCP*) do Departamento de Automação de Sistemas da Universidade Federal de Santa Catarina aplicou tal solução e tem desenvolvido vários processos práticos em escala de laboratório que possibilitam a aplicação das mais variadas técnicas de controle como o controle clássico, adaptativo, inteligente, em estruturas de malha *SISO* (*single input - single output*) ou multivariável.

Neste capítulo são apresentados os resultados obtidos na aplicação das técnicas ilustradas nos capítulos anteriores no processo *Fan and Plate*.

5.2 *Fan and Plate*

O processo *Fan and Plate* pode ser considerado como uma planta em escala de laboratório bem conhecida e está presente em várias universidades para atividades de aprendizado e pesquisa. O processo é constituído de um ventilador alimentado por um motor DC, um duto de ar de 50 cm de comprimento com características de funilamento, e, na sua extremidade esquerda, possui uma placa retangular (Fig. 5.1). O motor DC é alimentado por um circuito de atuação com entrada compatível com a saída do conversor D/A. A variável de saída é a deflexão angular da placa com a horizontal, medida através de uma célula fotocondutora e conectada ao circuito de medição.

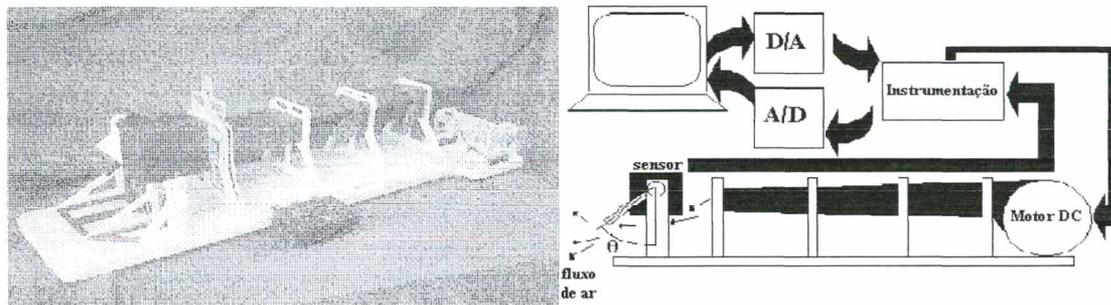


Figura 5.1 - Foto e diagrama físico do processo *Fan and Plate*.

O processo apresenta características complexas como um comportamento de fase não-mínima e dinâmica não-linear. Pode-se destacar o fato da variação de pressão do ar ser proporcional ao quadrado da velocidade do motor DC e a relação não-linear entre o ângulo da placa com a horizontal e a força atuante sobre a placa. O processo apresenta um certo grau de ruído devido à turbulência na saída do ar pelo tubo (Simas, 1998).

Para avaliação da característica não-linear do processo, utiliza-se um teste baseado no princípio da superposição e na resposta ao degrau em malha aberta (Thomson *et al.*, 1996). A partir de um nível de operação nominal $[u_0(t), y_0(t)]$, aplica-se uma mudança degrau no sinal de controle ($u_0(t) + \Delta u_1$) e mede-se o sinal de saída $y_1(t)$. Então retorna-se ao nível de operação nominal e aplica-se uma segunda mudança no sinal de controle ($u_0(t) + \Delta u_2$), onde Δu_2 é $\rho(t)$ vezes maior que Δu_1 , e mede-se o novo sinal de saída $y_2(t)$.

$$\rho(t) = \frac{\Delta u_2}{\Delta u_1} \quad (5.1)$$

Em seguida subtrai-se de cada resposta o valor de operação nominal $y_0(t)$ e calcula-se

$$\delta(t) = \frac{y_2(t) - y_0(t)}{y_1(t) - y_0(t)} \quad (5.2)$$

Para sistemas lineares têm-se a condição $\rho(t)=\delta(t)$, caso contrário o processo é não-linear. A tabela 5.1 ilustra as várias experiências realizadas, partindo-se do nível de operação nominal $u_0=3$ Volts e $y_0=1.25$ Volts.

Tabela 5.1 - Resultados para o teste da não-linearidade.

Controle	Saída
$u_0(t)=3.0$	$y_0(t)=1.25$
$u_1(t)=3.5$	$y_1(t)=3.12$
$u_2(t)=4.0$	$y_2(t)=4.5$

Como pode-se observar $\rho=2 \neq \delta=1.73$ caracterizando, assim, o processo *Fan and Plate* como não-linear.

5.3 Experimentos

Foram realizados experimentos de modelagem para identificação do processo e de rastreamento de trajetória para avaliação dos controladores. As experiências utilizaram um período de amostragem de 250 msec. Nas experimentações a magnitude do sinal de controle é ajustada entre zero e 5 Volts. Excessivas variações devem ser evitadas para prevenir imprecisões no funcionamento do sistema de controle digital (restrições físicas do experimento).

Os algoritmos de controle e identificação foram implementados na linguagem PASCAL[®], utilizando um computador 486 DX66. Foi utilizada a placa Clarabela para a conversão D/A e A/D.

5.3.1 Modelagem

Para a identificação do modelo utilizou-se um sinal *PRBS* na entrada com amplitudes de 2.5 e 4 Volts, num total de 1000 amostras, sendo que a probabilidade de mudança de amplitude era de 50%. Após cada mudança, o sinal permanecia na mesma amplitude por pelo menos 5 períodos de amostragem. A determinação da ordem dos modelos e do atraso de transporte foi realizada da mesma maneira descrita no capítulo 3. Os resultados obtidos foram:

- Modelo linear *CARMA* descrito em (3.2), com estimador *MQR(ML/MQR)* e $na = 3$ e $nb = 2$,

$$A(z^{-1}) = 1 - 1,3119z^{-1} + 0,5977z^{-2} - 0,0073z^{-3};$$

$$B(z^{-1}) = -0,0958z^{-1} + 0,3469z^{-2}$$

- Modelo linear *CARMA* descrito em (3.2), com estimador preditivo (*ML/EP*) e $na = 3$, $nb = 2$ e $hp = 8$,

$$A(z^{-1}) = 1 - 2,0530z^{-1} + 1,4203z^{-2} - 0,3317z^{-3}$$

$$B(z^{-1}) = 0,4845z^{-1} - 0,4526z^{-2}$$

- Modelo Volterra (*MV*), descrito em (3.7), utilizando $nh = 6$,

$$h_0 = 0,0700, h_1 = [-0,1505 \quad -1,2058 \quad 0,1174 \quad 0,1600 \quad -0,1168 \quad 0,0320],$$

$$h_2 = \begin{bmatrix} 0,0714 & 0,2362 & -0,051 & -0,0904 & -0,0780 & -0,0885 \\ 0 & 0,2701 & -0,0171 & -0,0566 & -0,0442 & -0,0546 \\ 0 & 0 & 0,0723 & 0,0329 & 0,0453 & 0,0348 \\ 0 & 0 & 0 & 0,0437 & 0,0561 & 0,0456 \\ 0 & 0 & 0 & 0 & 0,0420 & 0,0315 \\ 0 & 0 & 0 & 0 & 0 & 0,0281 \end{bmatrix}$$

- Modelo bilinear (*MB*), descrito em (3.6), utilizando $na = ny = 3$ e $nb = nu = 2$,

$$A(z^{-1}) = 1 - 1,2515z^{-1} + 0,5607z^{-2} + 0,3267z^{-3}$$

$$B(z^{-1}) = -0,1243z^{-1} + 0,3829z^{-2}$$

$$C = \begin{bmatrix} 0,3026 & -0,3314 \\ -0,4992 & 0,5181 \\ 0,2347 & -0,1264 \end{bmatrix}$$

- Modelo de Hammerstein (*MH*) descrito em (3.4) e (3.5), com $na = 3$, $nb = 2$ e $ny = 2$,

$$A(z^{-1}) = 1 - 1,0047z^{-1} + 0,3676z^{-2} + 0,0135z^{-3}$$

$$B(z^{-1}) = -0,0003z^{-1} + 0,0049z^{-2}$$

$$\gamma = [1 \quad 19,7380]$$

Para validação dos modelos, figura 5.2, foi usado um sinal ruído branco com amplitude variando entre 2.5 e 4.5 Volts, num total de 200 amostras. Após cada mudança, o sinal permanecia na mesma amplitude por pelo menos 5 amostras.

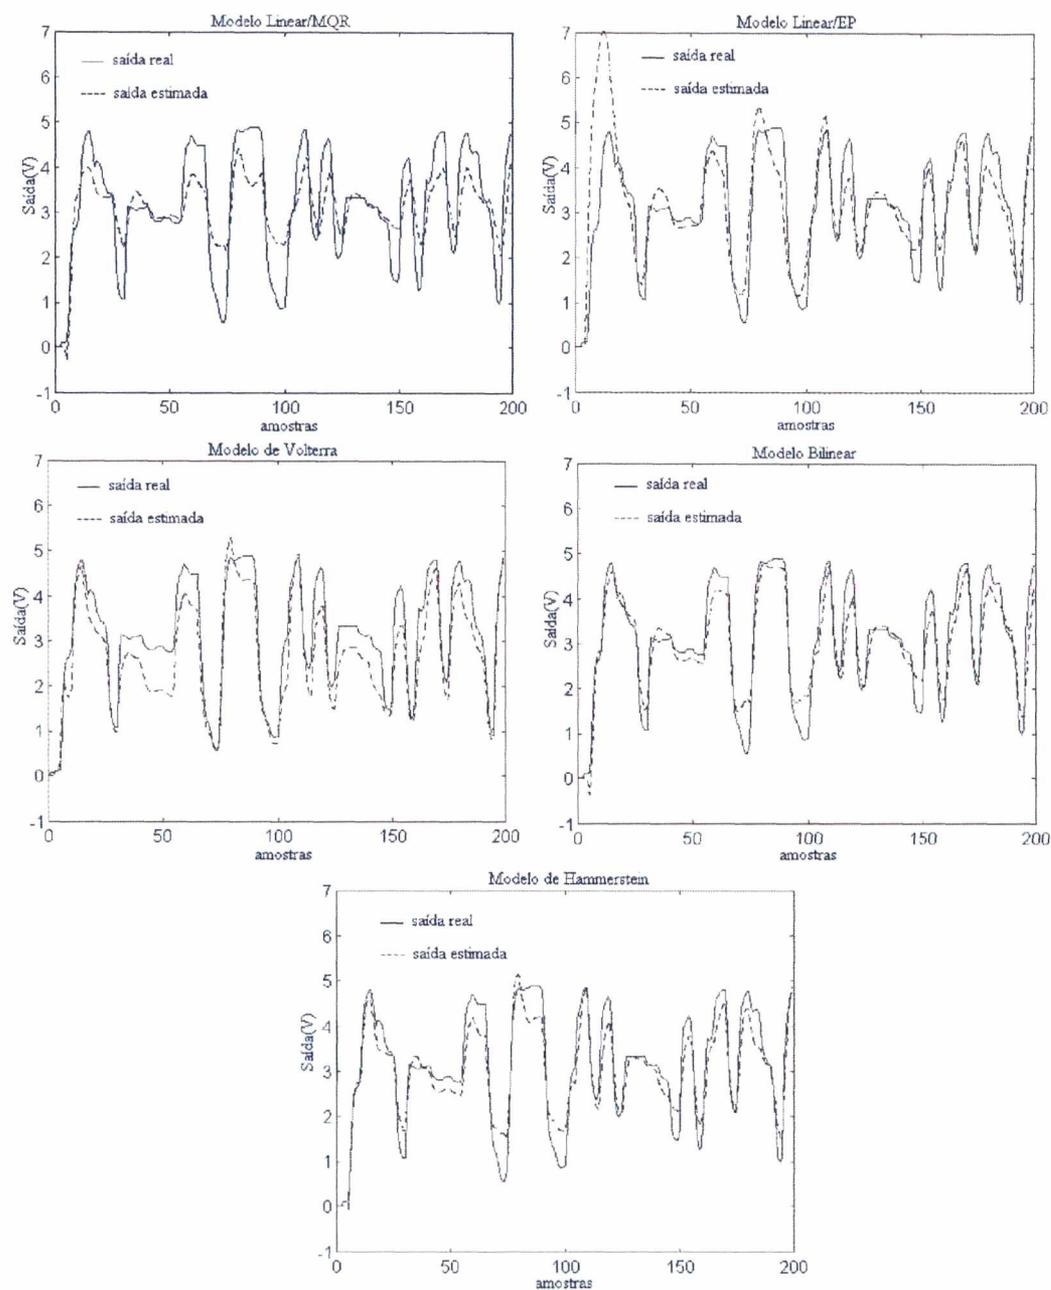


Figura 5.2 – Resultados da validação para os modelos estimados lineares e não-lineares.

Visando uma comparação quantitativa entre os modelos identificados utilizou-se também alguns índices de desempenho, como a soma do quadrado dos erros (*Sum of Square Error*) (Haber e Unbehauen, 1990). Este índice é bastante utilizado na literatura e representa a função de custo minimizada pelo *MQR*.

$$SSE = \frac{1}{N} \sum_{i=1}^N (y(i) - \hat{y}(i))^2 \quad (5.3)$$

onde N é o número total de amostras sobre as quais o *SSE* está sendo aplicado, $y(i)$ representa a saída do processo no instante i , e $\hat{y}(i)$ representa a saída estimada pelo modelo no instante i . Um *SSE* igual a zero indica uma combinação perfeita entre o modelo estimado e a planta, nos dados de validação.

Outro critério implementado foi o do coeficiente de múltipla correlação R^2 , conforme apresentado na equação (3.1). Também foi utilizado o critério *PI* (*Performance Index*) proposto por (Cunningham III *et al.*, 1996).

$$PI = \sqrt{\frac{\sum_{i=1}^N (y(i) - \hat{y}(i))^2}{\sum_{i=1}^N (\hat{y}(i) - \bar{\hat{y}})^2}} \quad (5.4)$$

Este índice não depende do fator de escala ou unidades utilizadas, não muda arbitrariamente com o aumento do número de dados de entrada e é uma boa indicação do quão boa é a combinação do modelo com a planta com respeito a variabilidade inerente do conjunto de dados utilizados. $PI \rightarrow 0$ indica uma combinação praticamente perfeita entre o modelo estimado e o processo, nos dados de validação. Estes índices foram aplicados nos dados de validação. Os resultados estão mostrados na tabela 5.2

Tabela 5.2 – Avaliação quantitativa do modelos estimados.

Modelo	SSE	R^2	PI
ML/MQR	0.5666	0.6606	0.9600
ML/EP	0.6122	0.6333	0.6075
MV	0.3399	0.7964	0.4771
MH	0.2011	0.8796	0.4379
MB	0.2015	0.8793	0.4210

Da tabela 5.2 pode-se observar que os modelos de Hammerstein e bilinear apresentaram os melhores índices, enquanto os modelos lineares obtiveram piores resultados. O modelo linear com o estimador preditivo foi penalizado pelo o problema inicial de seguimento da saída da planta.

Levantou-se também a característica estática de entrada e saída da planta e verificou-se quais dos modelos descritos aproximou melhor esta característica, obtendo-se o resultado mostrado na figura 5.3.

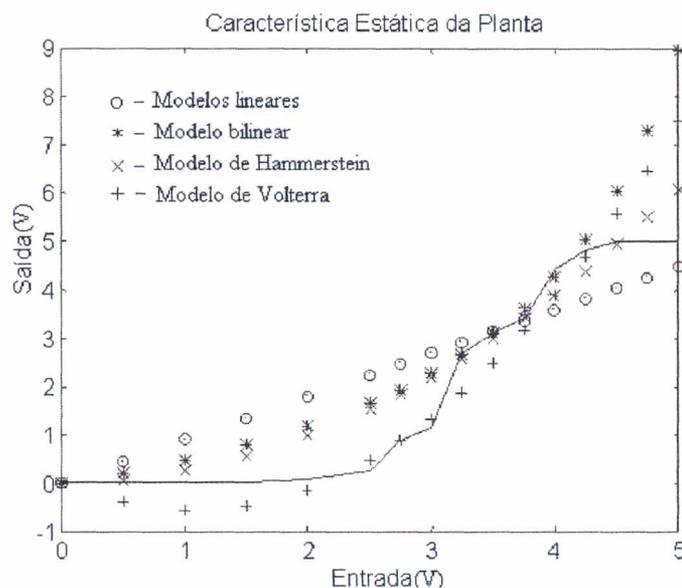


Figura 5.3 - Comparação entre os modelos através da característica estática da planta.

Pode-se observar que o modelo de Volterra aproxima melhor a curva estática, enquanto que os modelos de Hammerstein e bilinear apresentaram resultados muito próximos. Pode-se notar também que os modelos lineares aproximam bem a curva na faixa de 3 a 4 Volts.

5.3.2 Mudança de Setpoint

Para avaliação da capacidade de rastreamento da referência foram realizadas 450 amostras num tempo de experimentação total de 112 segundos. Inicialmente a referência foi ajustada em 1 Volt, depois modificada para 4 Volts, após 150 amostras, baixando para 2 Volts após 250 amostras e, finalmente, voltando a 4 Volts, após 350 amostras. A figura 4 ilustra a evolução da saída e do controle para a variação de *setpoint* correspondente a cada controlador *GPC*.

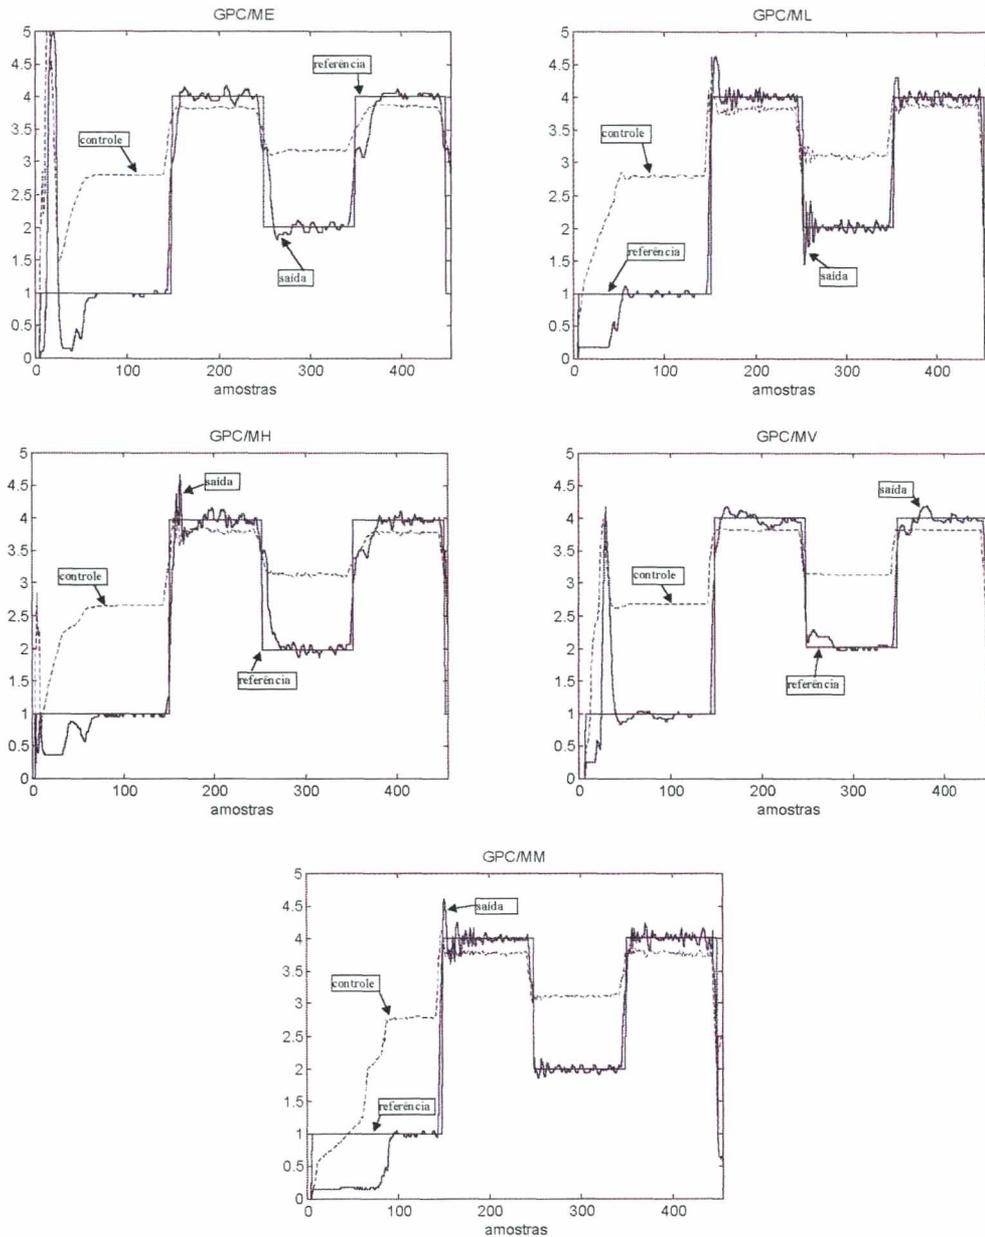


Figura 5.4 - Resultados para a experiência de mudanças de *setpoint*

onde *GPC/ML* e o *GPC/ME* denotam o controlador *GPC* utilizando modelo linear com o estimador *MQR* e o *EP*, respectivamente, *GPC/MH* é o controlador preditivo baseado no modelo de Hammerstein, *GPC/MV* representa o controlador preditivo baseado no modelo de Volterra e o *GPC/MM* é o controlador preditivo utilizando múltiplos modelos.

Não foi possível sintonizar adequadamente o controlador não-linear, descrito no item 4.5, utilizando o modelo bilinear, para o *Fan and Plate*. Possivelmente, isto deve-se ao fato do modelo não ser uma representação perfeita da planta e, portanto, o cancelamento da não-linearidade não foi obtida, impossibilitando uma ação de controle adequada. Destaca-se

o fato de ter se utilizado o controlador não-linear com o modelo bilinear, tendo em vista que a obtenção de um controlador preditivo similar ao *GPC/MH* ou *GPC/MV* para este tipo de representação é bastante complicado, como foi comentado por Sommer (1994).

No caso dos outros controladores, as estruturas de modelagem utilizadas foram as determinadas na seção 5.3.1, sendo que, para os estimadores, utilizou-se como condições iniciais $p=1000$ e $\theta(0) \neq 0$, onde p é o valor inicial de cada elemento da diagonal principal da matriz de covariância e $\theta(0)$ representa os valores iniciais dos parâmetros. Através da figura 5.4 observa-se que todos os controladores conseguiram rastrear a referência e que os controladores *GPC/ME* e *GPC/MV* foram os que apresentaram uma resposta mais suave da saída, porém com um grande sobressinal inicial na fase de sintonia do estimador. Este problema pode ser explicado devido à zona morta do processo, que prejudica sensivelmente o desempenho dos estimadores.

Para uma avaliação quantitativa do desempenho de cada controlador, adotou-se os seguintes índices de desempenho:

$$J_1 = \frac{1}{300} \sum_{k=151}^{450} (y_r(k) - y(k))^2 \quad (5.5)$$

$$J_2 = \frac{1}{300} \sum_{k=151}^{450} (u(k) - \bar{u})^2 \quad (5.6)$$

O índice J_1 (*Sum of the Square Error*) é usado para avaliar a capacidade de rastreamento do controlador e o índice J_2 avalia a variância do controle, onde \bar{u} representa o valor médio do controle no intervalo determinado. Na tabela 5.3 estão apresentados os resultados para cada índice, bem como a sintonia utilizada para cada controlador ($Hu=1$).

Tabela 5.3 - Resultados e sintonia obtidos para cada controlador.

Controlador	J_1	J_2	HY	Γ
GPC/ML	0.0732	0.1299	7	10
GPC/ME	0.1249	0.0919	7	10
GPC/MV	0.0695	0.1159	10	0,2
GPC/MH	0.1248	0.0928	10	1
GPC/MM	0.0662	0.1200	7	10

De acordo com estes índices pode-se notar que o controlador com múltiplos modelos apresentou um melhor rastreamento da referência e que o *GPC/ME* apresentou um controle mais suave do que os outros. Observando os resultados da figura 5.4, poder-se-ia esperar que o controlador *GPC/ME* apresentaria o melhor resultado para o índice J_1 , isto não se verificou, pelo fato de que, na passagem de 4 Volts a 2 Volts, o controlador é um pouco lento para seguir a referência e esta lentidão é penalizada no índice J_1 .

Para o controlador de múltiplos modelos, decidiu-se utilizar quatro modelos, um adaptativo e os outros três fixos, para a representação da planta. Idealmente, deve-se utilizar um número maior de modelos (> 100), para se obter melhores resultados. Os modelos fixos utilizados foram selecionados de um conjunto de modelos determinados através da identificação *off-line* por faixas de operação do processo (um modelo para a faixa de 1 a 2 Volts, outro para a faixa de 2 a 3 Volts, etc.) ou por meio de uma identificação em malha fechada utilizando o controlador *GPC*. Na tabela 5.4 mostra-se os modelos utilizados e na figura 5.5 apresenta-se o chaveamento entre os modelos durante a experimentação.

Tabela 5.4 - Estruturas utilizadas para o controlador com múltiplos modelos.

Número	Modelo
1	$(1 - 1.5306q^{-1} + 0.8151q^{-2} - 0.0735q^{-3})\Delta y(t) = (-0.0335q^{-1} + 0.0835q^{-2})\Delta u(t)$
2	$(1 - 1.74q^{-1} + 1.0423q^{-2} - 0.2149q^{-3})\Delta y(t) = (0.0003q^{-1} + 0.0544q^{-2})\Delta u(t)$
3	$(1 - 0.7404q^{-1} + 0.38q^{-2} - 0.018q^{-3})\Delta y(t) = (0.374q^{-1} + 1.0q^{-2})\Delta u(t)$
4	adaptativo, $p=1000$, $\theta(0)\neq 0$, $n_a=3$, $n_b=2$

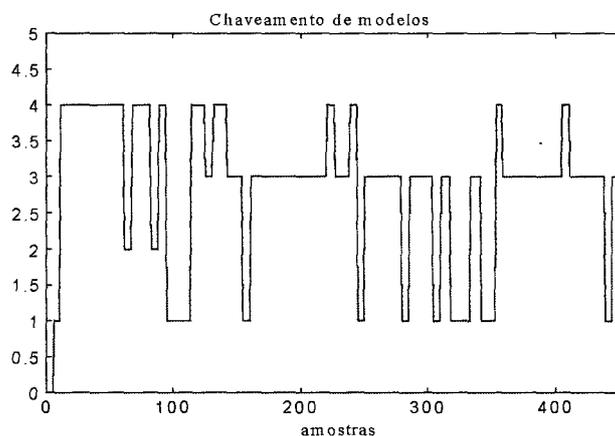


Figura 5.5 - Chaveamento entre os modelos utilizados durante o experimento.

Através da figura 5.5, nota-se que o modelo mais utilizado foi o nº 3, calibrado para operar na faixa em torno de 4 volts. Este resultado foi obtido utilizando-se a equação (4.27), com $\alpha = 2$ e $\beta = 0.5$.

5.4 Conclusão

Experimentações práticas foram realizadas com o objetivo de se testar as técnicas de controle e modelagem apresentadas nos capítulos 3 e 4. Utilizou-se o processo *Fan and Plate* para tais experimentos devido ao fato de ser um processo de fase não-mínima com características não-lineares, o que dificulta a utilização de técnicas convencionais e encoraja o uso de controle avançado.

Na experiência de modelagem, foram utilizados vários tipos de modelos tanto lineares como não-lineares para representar a planta e utilizou-se, no caso da representação linear, dois tipos de estimadores. Através de experimentos práticos realizou-se a validação dos modelos e uma avaliação quantitativa dos mesmos através de índices de desempenho. Verificou-se que os modelos bilinear e de Hammerstein obtiveram um melhor desempenho tanto no seguimento da saída, conforme apresentado na figura 5.2, como nos índices de desempenho. No entanto, observou-se que o modelo de Volterra foi o que melhor aproximou a característica estática da planta ao longo de sua faixa de operação.

Para a experiência de seguimento de trajetória, utilizou-se os controladores apresentados no capítulo 4. Analisando a figura 5.4, observa-se que todos os controladores apresentaram um bom rastreamento da referência, destacando-se o *GPC/MV* e o *GPC/MM*, a exceção do controlador *GPC/MB* que não conseguiu controlar a planta. Os índices de desempenho adotados mostraram que o *GPC/MM* apresentou o melhor rastreamento e o *GPC/ME* o controle mais suave (menor variância).

Considerando-se os resultados apresentados na figura 5.4 e na tabela 5.3, bem como a presença de sobressinais e oscilações na saída, pode-se considerar que o controlador com melhores resultados foi o *GPC/MV*, para o processo avaliado.

6. Comentários e Conclusão

Este trabalho tratou do problema da identificação e controle preditivo adaptativo para sistemas não-lineares. Foram apresentados vários tipos de modelos não-lineares e seus respectivos controladores, bem como dois tipos de estimadores: *MQR* e o *EP*. Também realizou-se experimentos de modelagem e seguimento de trajetória no processo *Fan and Plate* com o objetivo de avaliar e comparar o desempenho dos controladores GPC, estruturas de modelagem e dos estimadores.

No capítulo 2, apresentou-se os algoritmos de estimação. Discutiu-se sobre as principais características de cada um, e apresentou-se os passos básicos para implementação prática. Destaca-se a simplicidade e a habilidade do *MQR* para tratar de vários tipos de modelos, e, no caso do estimador preditivo, pode-se citar sua habilidade para tratar sistemas não-lineares, bem como a introdução de um filtro passa-faixa nas medidas, permitindo-se assim tratar o efeito das dinâmicas não-modeladas.

O capítulo 3 tratou das estruturas de modelagem utilizadas no trabalho. Utilizou-se um exemplo para ilustrar a avaliação e as características de cada estrutura. Através do exemplo, pode-se verificar que o estimador preditivo, embora obtenha melhores resultados que o *MQR* para o modelo linear, introduz uma grande carga computacional. Entre os modelos não-lineares, destaca-se o grande número de termos utilizados no modelo de Volterra para a descrição do sistema.

Para cada um dos modelos apresentados no capítulo 3, foram desenvolvidos algoritmos de controle preditivo adaptativo mostrados no capítulo 4. Neste caso, todos os controladores tiveram como base de projeto o *GPC*. Também apresentou-se a estratégia de múltiplos modelos para descrição do sistema.

No capítulo 5, apresentou-se os resultados dos experimentos realizados sobre a planta *Fan and Plate*. Uma pequena descrição do processo foi realizada, destacando-se suas principais características e realizou-se um teste para comprovar a não-linearidade do sistema. No experimento de modelagem, os modelos de Hammerstein e bilinear destacaram-se obtendo resultados adequados nos dados de validação, ressaltando-se que o modelo de Volterra foi o que melhor representou a curva de ganho estático do processo.

Na experiência de seguimento de trajetória, observou-se o bom desempenho dos controladores com múltiplos modelos e *GPCMV*. É importante ressaltar que o controlador baseado no modelo de Hammerstein e o *GPC* com estimador preditivo obtiveram um controle suave (baixa variância) e com menor sobressinal.

Pode-se citar como perspectivas de trabalhos futuros:

- Desenvolvimento de um software de supervisão, para melhoria do desempenho dos controladores;
- Utilização da estratégia de múltiplos modelos para modelos não-lineares;
- Desenvolvimento de um algoritmo que permita trocar a estrutura de modelagem que está sendo utilizada no momento pelo controlador, por exemplo: mudar de um modelo linear de 2 pólos e um zero para 3 pólos e dois zeros; mudar de um modelo linear para um não-linear, etc;
- Avaliação dos algoritmos aqui apresentados em outras plantas do Laboratório de Controle de Processos como o balanço horizontal, processo de nível, etc;
- Aplicação das tecnologias emergentes, como a lógica fuzzy, na sintonia do critério de seleção dos modelos no projeto do *GPC* com múltiplos modelos;
- Incorporar restrições sobre a saída, controle, variação do controle e sobressinal no projeto do *GPC* não-linear.

Referências Bibliográficas

- Agarwal, M. and Seborg, D. E. "Self-Tuning Controllers for Nonlinear Systems", *Automatica*, vol. 23, nº 2, p. 209-214, 1987.
- Aguirre, L. A.; Rodrigues, G. G. and Jácome, C. R. F. "Identificação de Sistemas Não-lineares Utilizando Modelos Narmax Polinomiais — Uma Revisão e Novos Resultados", *SBA Controle & Automação*, vol. 9, nº 2, p. 90-106, 1998.
- Aymes, J. M. and Bordeneve-Guibé, J. "Advanced Predictive Control for Aircraft Guidance", *Proc. 13th IFAC Triennial World Congress*, San Francisco, USA, p. 249-254, 1996.
- Bars, R. and Haber, R. "Weighted One-step-ahead Adaptive Predictive Control of Nonlinear Processes", *IMACS - Symposium MCTS*, Casablanca, Marrocos, p.16-21, 1991.
- Bequette, W. "Nonlinear Control of Chemical Processes: A Review", *Industrial Engineering Chemical Research*, vol. 30, nº 7, p. 1391-1413, 1991.

- Coelho, A. A. R. “*Notas de Aula*”, Curso de Identificação de Sistemas, UFSC, 1997.
- Cooper, D. J. and Lalonde, A. M. “Process Behavior Diagnosis and Adaptive Process Control”, *Computers Chemical Engineering*, vol. 14, n° 4, p. 541-549, 1990.
- Cunningham III, G. A. and Lin, Y., Coments on “A New Approach to Fuzzy-Neural System Modeling”, *IEEE Transactions on Fuzzy Systems*, vol. 4, n° 2, p. 209-210, 1996.
- Daniel-Beher, S. and Unbehauen, H. “Identification of Nonlinear Continuous-time Hammerstein Model via HMF-Method”, *Proceedings of the 36th Conference on Decision & Control*, San Diego, California, USA, p. 2990-2995, 1997.
- De Keyser, R. M. C.; Van de Velde, G. A. and Dumortier, F. A. G. “A Comparative Study of Self-Adaptive Long-Range Predictive Control Methods”, *Automatica*, vol. 24, n°2, p. 149-163, 1988.
- Eskinat, E.; Johnson, S. H. and Luyben, W. L. “Use of Hammerstein Models in Identification of Nonlinear Systems”, *AIChE Journal*, vol. 37, n° 2, p. 255-268, 1991.
- Fnaiech, F. and Ljung, L. “Recursive Identification of Bilinear Systems”, *International Journal of Control*, vol. 45, n° 2, p. 453-470, 1987.
- Fruzzetti, K. P.; Palazoglu, A., McDonald, K. A. “Nonlinear Model Predictive Control Using Hammerstein Models”, *Journal of Process Control*, vol. 7, n° 1, p. 31-41, 1997.
- Geng, G. and Geary, G. M. “The Control of Input-Constrained Nonlinear Processes Using Numerical Generalized Predictive Control Methods”, *IEEE Transactions on Industrial Eletronics*, vol. 45, n° 3, p. 496-501, 1998.
- Haber, R. and Unbehauen, H. “Structure Identification of Nonlinear Dynamic Systems —A Survey on Input/Output Approaches”, *Automatica*, vol. 26, n° 4, p.651-677, 1990.

- Hecker, O.; Knapp, T. and Isermann, R. "Robust Adaptive Control of a Time Varying Process Using Parallel Recursive Estimators" *Automatica*, vol.30, n° 4,p. 599-604, 1994.
- Hunt, K. J.; Munih, M., Donaldson, N. and Barr, F. M. D. "Optimal Control of Ankle Joint Moment: Toward Unsupported Standing in Paraplegia", *IEEE Transactions on Automatic Control* , vol.43, n° 6, p. 819-832, 1998.
- Krzyzak, A. and Sasiadek, J. Z. "Nonparametric Identification of Dynamic Nonlinear Systems", *Proceedings of the 36th Conference on Decision & Control*, San Diego, California, USA, p. 2996-2997, 1997.
- Mackay, M.; Thomson, M. and Soufian, M. "A Bilinear Non-Parametric Modelo Based Predictive Controller", *Proc. 13th IFAC Triennial World Congress*, San Francisco, USA, p. 359-364,1996.
- Marchi, P. A.; Rocha, C. R., Venturo, C. J., Bouzon, G., Simas, H., Coelho, A. A. R. "Aspectos em Identificação, Projeto e Experimentação de Algoritmos de Controle Adaptativo e Preditivo Indireto e Direto", *XII Congresso Brasileiro de Automática*, Uberlândia, MG, vol.2, p. 567-572, 1998.
- Marchi, P. A.; Rocha, C. R., Venturo, C. J., Bouzon, G., Simas, H., Coelho, A. A. R. "Avaliação Experimental de Algoritmos de Controle Auto-Ajustável Indireto e Direto", *Anais do 8º Congresso e Exposição Internacional de Automação*, vol.1, p. 134-139, 1998.
- Marchi, P. A. e Coelho, A. A. R. "Aspectos de Modelagem e Identificação no Controle Preditivo de um Processo Balanço Horizontal", *Seminário e Exposição de Instrumentação e Automação*, Rio de Janeiro, RJ, 1998.

- Marchi, P. A.; Coelho, L. S., Coelho, A. A. R. “Comparative Study of Parametric and Structural Methodologies in Identification of Experimental Nonlinear Process”, *IEEE International Conference on Control Applications*, Hawaii, USA, 1999 (submetido).
- Malik, O. P.; Hope, G. S., Cheng, S. J. “Some Issues on the Practical Use of Recursive Least Squares Identification in Self-tuning Control”, *International Journal of Control*, vol. 53, n° 5, p. 1021-1033, 1991.
- Morningred, J. D.; Paden, B. E., Seborg, D. E. and Mellichamp, D. A. “An Adaptive Nonlinear Predictive Controller”, *Chemical Engineering Science*, vol. 47, n° 4, p. 755-762, 1992.
- Narendra, K. S. and Balakrishnan, J. “Improving Transient Response of Adaptive Control Systems Using Multiples Models and Switching”, *IEEE Transactions on Automatic Control*, vol. 39, n° 9, p. 1861-1866, 1994.
- Narendra, K. S.; Balakrishnan, J., Ciliz, M. K. “Adaptation and Learning Using Multiples Models, Switching and Tuning”, *IEEE Control Systems*, p. 37-51, 1995
- Narendra, K. S. and Balakrishnan, J. “Adaptive Control Using Multiple Models”, *IEEE Transactions on Automatic Control*, vol. 42, n° 2, p. 171-187, 1997.
- Patwardham, R. S.; Lakshiminarayanan, S., Shah, S. L. “Constrained Nonlinear MPC Using Hammerstein and Wiener Models: PLS Framework”, *AIChE Journal*, vol.44, n° 7, p. 1611-1622, 1998.
- Qin, S. J. and Badgwell, T. J. “An Overview of Industrial Model Predictive Control Technology”, *AIChE Symposium Series 316*, vol. 93, p. 232-256, 1996, disponível em <http://www.che.utexas.edu/~qin/publicat.html>.
- Rani, K. Y. and Unbehauen, H. “Tuning and Auto-Tuning in Predictive Control”, *Proc. 13th IFAC Triennial World Congress*, San Francisco, USA, p. 109-114, 1996.

- Roux, G.; Dahou, B., Queinnec, I. "Modelling and Estimation Aspects of Adaptive Predictive Control in a Fermentation Process", *Control Engineering Practice*, vol. 4, nº 1, p. 55-66, 1996.
- Sales, K. R. and Billings, S. A. "Self-Tuning Control of Nonlinear ARMAX Models", *International Journal of Control*, vol. 51, nº 4, 753-769, 1990.
- Santos, J. E. "Critérios de Desempenho e Aspectos de Robustez na Síntese de Controladores Preditivos Adaptativos", Dissertação de Mestrado, Universidade Federal de Santa Catarina, 1997.
- Schaibel, B.; Xie, H., Lee, Y.C. "Fuzzy Logic Models for Ranking Process Effects", *IEEE Transactions. on Fuzzy Systems*, vol. 5, nº 4, p.545-556, nov. 1997.
- Simas, H. "Uma Contribuição ao Desenvolvimento e Implementação de Processos em Escala de Laboratório para Controle", Dissertação de Mestrado, Universidade Federal de Santa Catarina, 1998.
- Shah, S. L. and Cluett, W. R. "Recursive Least Squares Based Estimation Schemes for Self-tuning Control", *The Canadian Journal of Chemical Engineering*, vol. 69, p. 89-96, 1991.
- Shook, D. S.; Mothadi, C., Shah, S. L. "Identification for Long-Range Predictive Control", *IEE Proceedings Part D*, vol. 138, nº 1, p. 75-84, 1991.
- Sommer, St. "Model-based Predictive Control Methods Based on Nonlinear and Bilinear Parametric System Descriptions", *Advances in Model Based Predictive Control*, Oxford University Press Inc., New York, p. 192-204, 1994.
- Svoronos, S. Stephanopoulos, G. and Aris, R. "On Bilinear Estimation and Control", *International Journal of Control*, vol. 34, nº 4, p. 651-684, 1981.

Thomson, M.; Schooling, S. P. and Soufian, M. "The Pratical Application of a Nonlinear Identification Methodology", *Control Engeneering Praticce*, vol. 4, nº 3, p. 295-306, 1996.

Zhu, Q. M.; Warwick, K., Douce, J. L. "Adaptive General Predictive Controller for Nonlinear Systems", *IEE Proceodings Part D*, vol. 138, nº 1, p. 33-40, 1991.